



高端科技专著丛书

# 分布式信息融合

## ——理论与方法

Distributed Information Fusion: theory and Methods

◆ 赵宗贵 刁联旺 李君灵 吴蔚 著



中国工信出版集团



电子工业出版社  
PUBLISHING HOUSE OF ELECTRONICS INDUSTRY  
<http://www.phei.com.cn>



## 作者简介

赵宗贵,男,1943年2月12日生,黑龙江铁力市人,1965年7月毕业于哈尔滨工业大学计算数学专业,研究员,博士生导师。曾任电子工业部第二十八研究所科技委主任、副总工程师,总装备部电子信息系统综合技术专业组专家。长期从事C<sup>4</sup>ISR系统论证、设计和研制工作,曾任空军、海军、陆军多项大型电子系统工程主师、副总师、总师。获国家科技进步一等奖和电子部科技进步特等奖各1项,部委科技进步一等奖2项、二等奖3项,以及光华科技基金奖。被授予国家中青年有突出贡献专家称号,享受国务院特殊津贴。指导信息融合等领域博士10名、博士后20余名。参加撰写专著2部,主笔撰写《信息融合概念、方法与应用》、《信息融合工程实践—技术与方法》等专著。发表学术论文80余篇。

高端科技专著丛书

# 分布式信息融合 ——理论与方法

Distributed Information Fusion: Theory and Methods

赵宗贵 刁联旺 李君灵 吴蔚 著

电子工业出版社

Publishing House of Electronics Industry

北京 • BEIJING

## 内 容 简 介

本书系统深入地阐述了分布式信息融合的理论与方法,作者将自己在信息融合方向的研究成果和对国内外最新研究动态与成果的理解及对其中错误的修正意见奉献给相关专业的研究人员,以促进和引领国内分布式信息融合领域的发展和应用。

全书共 11 章,主要介绍了信息融合学科及其向分布式发展的动因、趋势和挑战性问题,分布式信息融合中的新概念和新方法,分布式融合系统的结构与估计算法,多传感器特别是无线传感网络(WSN)面对的分布式目标联合检测理论和实现算法,多传感器多目标跟踪中各类分布式融合准则和关联度量指标,分布式目标分类识别的特征、类型、结构和分类方法,分布环境中的威胁估计方法,一致性数据融合的概念和多传感器分布式管理算法以及分布式融合发展的理论基础等内容。

本书可作为信息融合学科高年级本科生、研究生的参考学习用书,也可供从事相关领域研究的高校教师、科研人员及从事相关行业的工程技术人员阅读参考。

未经许可,不得以任何方式复制或抄袭本书之部分或全部内容。  
版权所有,侵权必究。

### 图书在版编目(CIP)数据

分布式信息融合:理论与方法 / 赵宗贵等著. —北京:电子工业出版社, 2018.9

(高端科技专著丛书)

ISBN 978-7-121-33119-0

I. ①分… II. ①赵… III. ①信息融合—研究 IV. ①G202

中国版本图书馆 CIP 数据核字(2017)第 293120 号

责任编辑:张 剑

封面设计:张 昱

印 刷:

装 订:

出版发行:电子工业出版社

北京市海淀区万寿路 173 信箱 邮编 100036

开 本: 787×1 092 1/16 印张: 25.25 字数: 646.4 千字

版 次: 2018 年 9 月第 1 版

印 次: 2018 年 9 月第 1 次印刷

印 数: 1500 册 定价: 88.00 元

凡所购买电子工业出版社图书有缺损问题,请向购买书店调换。若书店售缺,请与本社发行部联系,联系及邮购电话:(010) 88254888, 88258888。

质量投诉请发邮件至 [zltz@phei.com.cn](mailto:zltz@phei.com.cn), 盗版侵权举报请发邮件至 [dbqq@phei.com.cn](mailto:dbqq@phei.com.cn)。

本书咨询联系方式: [zhang@phei.com.cn](mailto:zhang@phei.com.cn)。



## 序

信息时代产生的网络中心战（NCW）催生了分布式信息融合。其概念、技术与方法对基于网络的军事领域态势感知及民用领域环境感知都具有非常重要的价值，因而有学者认为，分布式信息融合已成为与大数据和云计算并驾齐驱的改变人类传统观念的当代信息处理技术之一，是当今信息融合学科发展的一个重要方向。

本书主笔赵宗贵研究员自 1965 年从哈尔滨工业大学毕业以来，一直在  $C^4ISR$  领域工作，是我国信息融合学科的开拓者之一。1993 年 2 月，他把美国 JDL 融合专家 E L Waltz 与 J Llinas 的专著《多传感器数据融合》一书引入国内，成为促进我国信息融合学界发展的里程碑。近三十年来，他与其团队一直从事战场态势感知信息融合领域的理论、方法和工程技术的研究和开发工作。作为我国信息融合学会指导委员会委员，赵宗贵研究员多次应邀在全国信息融合年会做报告并在国内外相关学术期刊上发表多篇论文；作为中国人民解放军陆军工程大学和中国电子科学研究院的博士生导师，先后培养了信息融合领域十余名博士和二十余名博士后；领衔研制的我军多军兵种  $C^4ISR$  系统装备应用于陆、海、空军，填补了多项空白，为我军指挥信息系统建设作出了突出贡献；1993 年享受国务院特殊津贴；1998 年被国务院授予自然科学类“有突出贡献的中青年专家”称号。

近二十年来，赵宗贵研究员以敏锐的眼光和扎实的专业功底，一直跟踪和致力于分布式融合领域的研究。本书是他继《信息融合概念、方法与应用》《信息融合工程实践——技术与方法》两部专著后，又一部信息融合领域的力作，展现了他在分布式信息融合领域的研究和工程应用成果。本书的第一个特点是创新性，清晰地描述了与传统集中式融合不同的分布式融合新概念、新问题和新方法，如分布式融合中的相关性、信息重用、信息价值等新概念，以及有界协方差控制、信用估计和效用计算等新方法；第二个特点是前瞻性，分布式融合位于融合学科前沿，是面向信息时代分布式应用产生的，建立了分布式信息融合的相关性准则、精度准则和分级融合方法，以及作为理论基础的概率假设密度滤波和基数概率假设密度滤波等具有前瞻性的分布式融合理论和方法；第三个特点是综合性，本书几乎包含了当前分布式融合领域所有已经出现的研究成果，如分布式融合结构，分布式目标检测、分类识别与跟踪算法，分布式威胁估计，以及分布式感知资源管理算法等，为进一步研究分布式融合奠定了基础；第四个特点是应用性，本书是作者从工程技术研究实践中总结经验撰写的，具有显著的应用特征，从书中所述的网络中心战对分布式信息融合的需求和应用案例可以看出这一点。

本书的出版和发行将会推动和繁荣我国信息融合学科理论和技术的研究，并产生很大的社会和军事效益。期望赵宗贵研究员及其团队为我国信息融合学科的发展作出新的贡献。

中国工程院院士

费爱国

2016 年 12 月



# 前 言

由于分布式应用的驱动，关于分布式信息融合的一些技术和方法由来已久，但直到 21 世纪初才出现分布式信息融合这一新概念，其含义是将传统集中式的单点信息融合扩展为多点网状信息融合。在步入信息时代的今天，信息技术、信息产品及人类观念的信息化正在使当今社会发生翻天覆地的变化。其中之一就是全球范围内人类活动正在加速向分布式扩展，包括行业内分布式经营活动、多行业分布贯通、大范围信息分布共享，以及大范围/多业务分布应用交互等正在成为产生分布式感知应用需求的持续动力。特别是在当前这场新军事变革所产生网络中心战需求的驱动下，无处不在、随时可用的网络连接支撑着分布式信息融合技术与应用的迅速发展。美国国防部实验室联合理事会（JDL）数据融合专业组于 2005 年将分布式信息融合作为信息融合学科的一个重要发展方向，旨在实现信息融合在技术上与信息网络的紧密耦合，在应用上与分布式需求，特别是网络中心战的分布式战场感知需求紧密耦合，以使信息融合科学具有更广阔的发展空间、更活跃的生命力和更深入的边缘学科凝聚力，从而对信息时代人类认识世界和改造世界的科研与实践活动提供更加有力、有效的支持。

与计算机网络合为一体的网状分布式信息融合结构产生了与传统单一点状集中式融合结构大不相同的新概念、新技术和新方法。其中既有从集中式融合引申出来、向分布式融合扩展的概念和方法，又有分布式融合特有的创新概念和方法，以及取自其他学科用来解决分布式融合新问题的技术和方法，如与集中式融合完全不同的相关性概念，网络融合结构和信息图产生的信息重复计入（重用），反复分布式信息融合中的共用过程噪声和共用先验信息，多传感器协同探测、信息接入与传输路径、网络节点的信用估计与信息交换对象的选择、节点自利行为与利它行为的全局控制，以及在系统资源（网络带宽、探测传感器、融合软件、信息效用、信息成本等）统一约束下的融合网络结构优化等都是分布式信息融合出现的新概念和新问题。此外，由于集中式融合中的两个统计独立性假设（不同来源信息相互独立、不同时间信息相互独立）在分布式信息融合中已不再成立（不能够忽略），因此在分布式目标检测、分布式目标跟踪、分布式目标识别及分布式估计算法中都出现了许多有待解决的技术和方法。到目前为止，国际信息融合学界，特别是 JDL 顶级融合专家们将该融合方向的论文汇编成专著出版。其中包含了近十年来关于分布式信息融合的重要研究成果。这些专著主要有：

- David L. Hall, Chee-Yee Chang, James Llinas, Martin Liggins II, Distributed Data Fusion for Network-Centric Operations, 2013.
- Paul M. Salmon, Neville A. Stanton, Guy, H., Walker, Daniel P. Jenkins ed., Distributed Situation Awareness: theory, measurement and Application to teamwork, 2009.
- David L. Hall, John M. Jordon. Human-Centered Information Fusion, 2010.
- Erik Blasch, Éloi Bossé, Dalc A. Lambert ed., High-Level Information Fusion Management and Systems Design, 2012.

- Dvauid L. Hall , Sonya A. H. McMullen. Mathematical Techniquis in Multisensor Data Fusion, 2004.
- Martin E. Liggins, David L. Hall, James Llinas, ed., Handbook of Multisensor Data Fusion-Theory and Practice, 2009.

这些专著中的研究成果大多处于理论和方法层面上, 工程应用以集中式融合向分布式扩展的成果居多, 创新成果应用尚不多见, 但从中可以看出分布式信息融合的广泛需求和广阔应用前景。

国内自 2009 年成立信息融合分会以来, 信息融合理论和方法研究及技术应用得到了迅速发展。自 2005 年以来, 笔者一直跟踪分布式信息融合方向发展动态, 并进行该领域的研究, 包括对已有分布式融合方法和应用技术进行总结和提升, 以及开展分布式信息融合新方法研究。笔者曾在全国信息融合第二届年会(2010 年杭州)上做了分布式融合结构与应用的报告, 并在 2012 年国防工业出版社出版的专著《信息融合概念、方法与应用》中, 以一章的篇幅描述了分布式系统中的信息融合结构、原理、算法及工程应用的结构与案例。笔者还在国内工业部门和高校、军事研究院所和院校举办信息融合讲座, 培训分布式融合科研和工程技术人员。上海交通大学史习智教授主持翻译出版了美国顶级融合专家 David L.Hall, Chee-Yee Chang, James Llinas 编辑的论文集《面向网络中心战的分布式数据融合》。国内高校和企业对分布式信息融合领域的研究也开始起步, 主要单位有杭州电子科技大学、上海交通大学、海军航空工程大学、西安交通大学, 以及一些国防工业集团的研究所, 如中国电科集团 28 所、中船重工集团 709 所和 716 所等。在这期间, 国内陆续出现一些关于分布式信息融合的论文, 但关于分布式新概念和新方法的研究基本上处于理论、概念和方法层面上, 在应用层面上, 与国外状况类似, 主要是从传统集中式信息融合扩展的一些成果, 如多传感器分布式检测、分布式目标跟踪与分类识别等。分布式结构与估计算法也有一定程度的应用。

本书出版的动因主要有两个: 第一个是响应我军在信息化转型中, 保卫国家领土、领海和领空主权所面临的信息化战争对分布式感知的需求; 第二个是笔者将自己在信息融合方向的研究成果和对国内外最新研究动态与成果的理解及对其中错误的修正意见奉献给有关研究人员, 以促进和引领国内分布式信息融合领域的发展和应用。本书前两章介绍了信息融合学科及其向分布式发展的动因、趋势和挑战性问题, 特别描述了网络中心战的特征及其对分布式信息融合的需求; 第 3 章描述了分布式信息融合中的新概念和新方法, 给出了对其中一些概念、方法和公式的理解、推导及修正; 第 4 章重点介绍了分布式融合系统的结构与估计算法; 第 5 章介绍了多传感器, 特别是无线传感网络(WSN)面对的分布式目标联合检测理论和实现算法; 第 6 章介绍了多传感器多目标跟踪中各类分布式融合准则和关联度量指标, 并给出了仿真案例; 第 7 章介绍了分布式目标分类识别的特征、类型、结构和分类方法, 并对各种识别算法进行了比较和评估; 第 8 章介绍了一致性数据融合概念, 为读者指出了实现数据融合的准则和方法; 第 9 章的分布式融合发展的理论基础是从学科发展角度出发的, 向读者展示了对已有理论和方法的总结和创新应用所依据的理论和方法, 为该融合方向的理论研究奠定了基础; 第 10 章描述了分布环境中的威胁估计方法, 包括单一重要目标的威胁、估计方法和集群目标的威胁估计方法; 第 11 章给出了多传感器分布式管理算法, 特别是基于效用函数的传感器管理算法、基于模糊推理的传感器管理算法和具有新意的基于市场拍卖机制

的资源管理算法。

本书第 1 章至第 7 章和第 9 章由赵宗贵研究员撰写，第 8、10、11 章由刁联旺博士撰写，李君灵博士参与了对第 3、5、9 章的编写和修改，吴蔚高工参与了第 6、7 章的编写和修改。赵宗贵研究员对所有章节进行了审查和多次修改。本书的文字录入、编辑和修改工作是由李君灵博士、许阳博士、吴蔚高工、张武博士、郑重博士、施展博士、马文婷博士、李晓冬工程师等共同完成的。笔者对他们不厌其烦、认真负责的工作表示感谢，还要感谢中国电科 28 所的各级领导，特别是信息系统工程重点实验室常务副主任王珩博士、中国电科 28 所副所长吴振锋博士和所长毛永庆研究员。他们对本书的撰写和出版提供了环境和人力、物力资源。

本书被国防科技图书出版基金评审委员会于 2017 年 12 月审定为国防科技优秀图书，并给予出版基金资助，我们要感谢中国工程院费爱国院士、杨小牛院士，以及杭州电子科技大学校长薛安克教授对本书申请国防科技图书出版基金资助的推荐，为本书的顺利出版和发行创造了有利条件。

由于分布式信息融合是一个刚刚出现的新的研究方向，囿于笔者的知识和经验，本书中出现的不准确理解、不足甚至错误之处，敬请读者指正。

赵宗贵

2016 年 11 月于南京



# 目 录

第 1 章 信息融合及其分布式发展概述.....	1
1.1 信息融合技术发展沿革.....	1
1.2 数据融合模型的概要分类.....	2
1.3 JDL 数据融合过程模型.....	3
1.3.1 JDL 数据融合结构模型.....	4
1.3.2 JDL 顶层融合模型的演变.....	5
1.3.3 JDL 融合顶层模型的主要功能.....	7
1.4 Endsley 态势感知模型.....	8
1.5 影响信息融合学科发展的相关动向.....	9
1.6 信息时代对分布式信息融合的需求.....	12
1.7 分布式融合面临的主要挑战.....	14
参考文献.....	17
第 2 章 面向网络中心战的分布式信息融合.....	23
2.1 网络中心战 (NCW) 的概念及背景.....	23
2.1.1 新军事变革与联合作战.....	23
2.1.2 新军事变革与信息化.....	24
2.1.3 新军事变革与网络中心战.....	24
2.2 网络中心战 (NCW) 中的信息价值.....	26
2.2.1 网络中心战 (NCW) 中的信息价值概念.....	26
2.2.2 网络中心战 (NCW) 中的价值链.....	26
2.2.3 最优行动的期望效用.....	29
2.3 网络中心战 (NCW) 中的认知问题.....	30
2.3.1 认知的概念.....	30
2.3.2 认知的本质和过程.....	32
2.4 网络中心战 (NCW) 中的自组织和自同步.....	34
2.4.1 网络中心战 (NCW) 的主要特征.....	34
2.4.2 自组织的概念和效用.....	35
2.4.3 自同步的概念和效用.....	35
2.5 分布式信息融合在网络中心战 (NCW) 中的作用.....	36
2.5.1 分布式网络中心战 (NCW) 与分布式信息融合.....	36
2.5.2 信息融合对网络中心战 (NCW) 价值链的贡献.....	37
2.5.3 信息融合在网络中心战 (NCW) 认知中的作用.....	38
2.5.4 信息融合在网络中心战 (NCW) 指挥控制中的作用.....	39
2.6 分布式信息融合中的挑战性问题.....	41



参考文献 .....	42
<b>第 3 章 分布式信息融合中的新概念和新方法 .....</b>	<b>45</b>
3.1 引言 .....	45
3.2 分布式信息融合概念与问题概述 .....	46
3.3 控制相关信息融合误差的有界协方差增长方法 .....	50
3.3.1 有界协方差增长控制方法的概念和应用背景 .....	50
3.3.2 BCI 模型 .....	50
3.3.3 分散式目标跟踪误差分析案例 .....	54
3.4 传感器协同方法 .....	56
3.4.1 极大和算法模型 .....	57
3.4.2 极大和算法约束条件与模型求解 .....	58
3.4.3 基于极大和算法的多传感器协同跟踪案例 .....	61
3.5 自利平台的优化协调方法 .....	63
3.5.1 概念与背景 .....	63
3.5.2 目标跟踪中的多代理协调问题 .....	64
3.5.3 目标跟踪 MAS 模型的效用评价函数 .....	65
3.5.4 考虑信道衰减的信息多级最优传输路径 .....	66
3.5.5 基于拍卖机制的网络带宽优化分配 .....	67
3.5.6 仿真案例 .....	70
3.6 合作对象信用估计 .....	71
3.6.1 合同的期望效用与协方差的概念 .....	72
3.6.2 基于独立贝塔分布的合同信用估计 .....	72
3.6.3 基于卡尔曼滤波的异类服务合同信用估计 .....	73
3.6.4 合同信用模型仿真验证案例 .....	75
3.7 基于人—代理集合体 (HAC) 的分布式信息融合 .....	76
3.7.1 问题的提出 .....	76
3.7.2 人—代理集合体 (HAC) 中的用户精炼 .....	77
3.7.3 人—代理集合体 (HAC) 中的用户控制与管理 .....	82
3.7.4 用户在人—代理集合体 (HAC) 系统评估中的作用 .....	84
3.7.5 人—代理集合体 (HAC) 设计中的挑战与机遇 .....	86
3.8 本章小结 .....	87
参考文献 .....	88
<b>第 4 章 分布式融合结构与估计算法 .....</b>	<b>91</b>
4.1 引言 .....	91
4.2 分布式信息融合结构 .....	92
4.2.1 融合结构的依赖因素 .....	92
4.2.2 融合结构与依赖因素之间的关系 .....	93
4.2.3 分布式融合结构的选择基准 .....	95
4.2.4 分布式融合结构分类 .....	95

4.3 分布式融合信息图.....	98
4.3.1 单连接信息图.....	98
4.3.2 无反馈层次融合的多连接信息图及连接转换 .....	99
4.3.3 有反馈层次融合信息图及连接转换 .....	100
4.3.4 对等式分布融合信息图及连接转换 .....	101
4.4 分布式估计算法.....	105
4.4.1 分布式估计概述.....	105
4.4.2 贝叶斯分布估计中的重复信息去除原理 .....	106
4.4.3 最优贝叶斯分布融合算法 .....	108
4.4.4 次优贝叶斯分布融合算法 .....	112
4.4.5 高斯分布或带有误差协方差估计的全局估计 .....	114
4.5 目标跟踪中的分布式估计 .....	116
4.5.1 问题描述.....	116
4.5.2 确定性动态过程.....	117
4.5.3 非确定性动态过程.....	118
4.6 对象分类识别的分布式估计 .....	118
4.6.1 对象分类的分布式识别结构.....	119
4.6.2 对象分类的分布式识别算法 .....	120
4.7 本章小结 .....	121
参考文献 .....	121
 第 5 章 多传感器分布式目标检测 .....	 125
5.1 分布式检测问题描述.....	125
5.1.1 集中式与分布式检测.....	125
5.1.2 分布式检测结构与模型.....	126
5.2 基于 LRT 的分布式检测方法 .....	128
5.2.1 贝叶斯分布式检测.....	128
5.2.2 基于 LRT 的奈曼—皮尔逊检测方法.....	134
5.2.3 基于 LRT 的融合检测逻辑设计 .....	136
5.3 基于计数表决规则的 WSN 检测方法 .....	139
5.3.1 计数表决检测方法.....	139
5.3.2 多传感器全局表决检测准则.....	140
5.3.3 不同性能传感器的全局表决检测通用模型 .....	141
5.3.4 同类传感器表决检测通用模型 .....	142
5.4 基于虚发现率的分布式检测门限控制 .....	143
5.4.1 统计学中的多比较问题.....	144
5.4.2 基于 FDR 局部门限控制的全局优化检测算法 .....	144
5.4.3 基于 FDR 的分布式检测系统设计 .....	146
5.5 相关情况的分布式检测.....	148
5.5.1 基于相关观测的最优分布式检测研究现状 .....	148
5.5.2 基于相关局部判定的最优分布式检测研究现状 .....	149

5.5.3 进一步说明.....	149
5.6 非理想通信信道下的分布式检测.....	150
5.6.1 概念与模型.....	150
5.6.2 考虑信道衰减的分布式检测规则.....	151
5.6.3 基于部分信道状态的分布式检测.....	152
5.6.4 具有非信道状态信息的分布式检测.....	153
5.7 本章小结.....	154
参考文献.....	155
<b>第6章 航迹融合与航迹关联——分布式多目标跟踪要点.....</b>	<b>161</b>
6.1 引言.....	161
6.2 航迹融合的概念与模型.....	163
6.2.1 目标动态与观测模型.....	164
6.2.2 一次航迹融合的概念.....	164
6.2.3 反复航迹融合的概念.....	165
6.3 一次航迹融合准则.....	166
6.3.1 一次航迹融合状态估计及其协方差.....	166
6.3.2 融合准则.....	168
6.3.3 航迹融合准则性能评估基准.....	174
6.4 一次航迹融合准则性能评估案例.....	178
6.4.1 案例剧情模型.....	178
6.4.2 追加传感器情况仿真案例.....	180
6.4.3 互补传感器情况仿真案例.....	183
6.5 目标连续跟踪中的反复航迹融合.....	185
6.5.1 反复航迹融合结构与分类.....	185
6.5.2 不带反馈的反复航迹融合.....	187
6.5.3 带反馈的反复航迹融合.....	192
6.6 分布式航迹关联.....	195
6.6.1 航迹关联的基本假设与评估函数.....	196
6.6.2 航迹关联度量指标及其计算.....	197
6.6.3 航迹关联度量指标比较仿真案例.....	200
6.7 本章小结.....	203
参考文献.....	203
<b>第7章 分布式目标分类识别.....</b>	<b>208</b>
7.1 目标分类的概念与应用需求.....	208
7.2 目标分类/识别方法.....	209
7.2.1 基于不确定性的目标分类/识别方法.....	209
7.2.2 目标分类/识别的基本步骤.....	210
7.2.3 分布式目标分类识别方法的特点.....	211
7.2.4 目标类别与识别特征的关系.....	212

7.3 目标分类方法的基本类型.....	213
7.3.1 “产生”型目标分类识别方法.....	213
7.3.2 “差异”型目标分类识别方法.....	214
7.3.3 混合型目标分类识别方法.....	215
7.4 多级目标分类识别结构.....	217
7.5 分布式目标分类识别中的新问题.....	219
7.5.1 显式重复计算.....	220
7.5.2 隐式重复计算.....	221
7.5.3 采用硬说明的传统融合识别系统.....	221
7.5.4 混合不确定性表示.....	222
7.6 基于局部分类器的全局融合识别.....	223
7.6.1 多分类器融合技术的分类.....	223
7.6.2 分类器组合方法.....	224
7.7 最优分布式贝叶斯目标分类方法.....	226
7.7.1 集中式目标分类算法.....	227
7.7.2 分布式目标分类算法.....	227
7.7.3 分布式目标分类识别系统的通信策略.....	232
7.8 分布式目标分类识别算法比较.....	233
7.8.1 目标分类识别算法性能仿真与评估方法.....	233
7.8.2 目标分类融合识别算法仿真比较.....	234
7.9 本章小结.....	238
参考文献.....	239
<b>第 8 章 多传感器一致性数据融合.....</b>	<b>241</b>
8.1 引言.....	241
8.2 基于分位数的离异值剔除方法.....	245
8.2.1 一维情形.....	245
8.2.2 多维情形.....	247
8.3 基于模糊集理论的多传感器一致性数据融合.....	248
8.4 基于统计距离矩阵特征值的一致性数据融合.....	249
8.5 基于置信距离的多传感器一致性数据融合.....	251
8.5.1 一维情形的置信距离.....	251
8.5.2 多维情形的置信距离.....	252
8.5.3 基于置信距离的一致性数据融合方法.....	252
8.6 基于测量精度分级的多传感器一致性数据融合.....	254
8.6.1 两个传感器测量数据偏差的概率比较.....	254
8.6.2 两传感器融合偏差与传感器测量偏差的概率比较.....	256
8.6.3 基于精度分级的多传感器一致性数据融合实现方法.....	258
8.6.4 计算案例.....	259
8.7 本章小结.....	261
参考文献.....	262

第 9 章 分布式信息融合发展的理论基础 .....	264
9.1 引言 .....	264
9.2 单目标分布式融合概述 .....	267
9.2.1 单目标贝叶斯滤波 .....	268
9.2.2 独立数据源的 $T^2F$ .....	269
9.2.3 非独立数据源的 $T^2F$ .....	272
9.2.4 协方差交集 (CI) 航迹融合 .....	276
9.2.5 指数混合 (XM) 融合 .....	278
9.3 基于有限集统计学的多目标滤波方法 .....	282
9.3.1 多传感器多目标递推贝叶斯滤波 .....	282
9.3.2 多目标随机分布的计算方法 .....	284
9.3.3 概率假设密度 (PHD) 滤波 .....	286
9.3.4 基数概率假设密度 (CPHD) 滤波 .....	288
9.3.5 基于随机集的滤波技术应用近况 .....	291
9.4 基于单目标融合扩展的多目标分布式融合 .....	292
9.4.1 独立数据源的多目标 $T^2F$ .....	292
9.4.2 非独立数据源的多目标 $T^2F$ .....	294
9.4.3 多目标指数混合 (XM) 融合 .....	294
9.5 基于 CPHD/PHD 滤波的多目标航迹融合公式 .....	295
9.5.1 基于 CPHD 滤波的独立跟踪源 $T^2F$ 公式 .....	295
9.5.2 基于 PHD 滤波的独立跟踪源 $T^2F$ 公式 .....	298
9.5.3 基于 CPHD 滤波和 PHD 滤波的相关跟踪源 $T^2F$ 公式 .....	300
9.5.4 基于 CPHD 滤波的多目标分布密度的指数混合 (XM) 融合近似 .....	301
9.5.5 基于 PHD 滤波的多目标分布密度的指数混合 (XM) 融合近似 .....	303
9.6 基于 CPHD 滤波和 PHD 滤波的多目标 $T^2F$ 实现案例 .....	306
9.6.1 基于 CPHD/PHD 滤波的多目标 $T^2F$ 公式实现 .....	306
9.6.2 多目标指数混合 (XM) $T^2F$ 近似公式的计算实现 .....	308
9.7 本章小结 .....	310
参考文献 .....	311
第 10 章 分布式环境中的威胁估计 .....	315
10.1 威胁估计基本概念 .....	315
10.1.1 威胁与威胁对象 .....	315
10.1.2 威胁估计概念 .....	315
10.1.3 威胁估计的特征与内涵 .....	317
10.1.4 威胁估计要素及其层次结构 .....	318
10.1.5 威胁估计结果的表示方法 .....	320
10.2 基于假设评估的威胁估计推理模型 .....	320
10.2.1 威胁估计模型 .....	320
10.2.2 威胁估计的多假设推理 .....	321

10.2.3 威胁估计推理中的多假设评估 .....	322
10.3 威胁估计方法 .....	324
10.3.1 基于随机区间的目标威胁估计方法 .....	324
10.3.2 基于模糊模式识别的目标威胁估计算法 .....	330
10.3.3 基于决策树学习的目标威胁估计算法 .....	339
10.4 多目标威胁估计方法 .....	342
10.4.1 威胁函数与威胁值 .....	342
10.4.2 基于多价值准则的多目标威胁评估方法 .....	343
10.5 分布式环境中目标威胁估计的控制模式 .....	346
10.5.1 分布式威胁估计的优势 .....	346
10.5.2 分布式威胁估计的环境要求 .....	346
10.5.3 分布式威胁估计的协同模式 .....	347
10.5.4 分布式协同威胁估计案例 .....	349
10.6 通信状态对分布式威胁估计的影响 .....	350
10.6.1 通信中断状态产生的影响 .....	350
10.6.2 通信降级状态产生的影响 .....	351
参考文献 .....	351
<b>第 11 章 分布式传感器管理 .....</b>	<b>354</b>
11.1 概述 .....	354
11.1.1 传感器管理的概念 .....	354
11.1.2 传感器管理的内涵和效用 .....	355
11.1.3 传感器管理的功能 .....	356
11.2 基于效用函数的目标探测传感器资源管理算法 .....	357
11.2.1 问题描述 .....	358
11.2.2 基于效用的传感器资源分配数学模型 .....	359
11.2.3 仿真例子 .....	362
11.3 基于模糊推理的传感器管理算法 .....	364
11.3.1 问题描述 .....	364
11.3.2 基于模糊推理的传感器管理算法 .....	365
11.3.3 性能指标 .....	368
11.3.4 仿真例子 .....	369
11.4 基于组合双向拍卖的传感器管理算法 .....	370
11.4.1 问题描述 .....	371
11.4.2 基于多资源组合双向拍卖的传感器管理算法 .....	372
11.4.3 仿真例子 .....	381
11.5 本章小结 .....	385
参考文献 .....	386

# 第 1 章 信息融合及其分布式发展概述

作为本书的开始，本章主要概述迄今为止信息融合学科的产生、发展、关键技术和模型以及当前信息融合向分布式发展的动因、概念和面临的主要挑战等内容。

## 1.1 信息融合技术发展沿革

信息融合学科也可以称为信息时代的数据融合，是随信息源类型的扩展、信息类别的增加（不只是传感器数据）以及应用领域的扩大和对应用支持程度的加深而从数据融合演变来的。数据融合起源于 20 世纪 70 年代，当时美国国防部拨款进行声呐信号理解研究，对多独立连续声呐信号进行融合，以检测某一海域中可能出现的水下目标<sup>[1]</sup>。实际上，由于人类认识事物通常由多感知信息综合获得，在数据融合概念出现之前两百多年，就已经出现了感知领域的一些统计综合方法和技术。从这个意义上讲，信息融合学科有着漫长的发展历史。18 世纪中叶，英国牧师贝叶斯（Thoms Bayes）辞世后 3 年出版的贝叶斯后验概率理论（1763），以及德国数学家高斯（K F Gauss）于 1795 年发明的最小平方估计（又称最小二乘法）就是最早的案例，高斯基于大量的大误差冗余观测，采用最小平方估计来确认小行星轨道，最终发现了小行星 Ceres。这里的冗余是指使用了比无误差观测确定初始轨道所需最少观测数据多得多的观测数据，从而开创了基于带有误差的多观测或传感器测量数据估计（运动或静止）实体状态（位置、速度、属性和身份）的各种统计估计方法的先河。文献[2, 3]以及许多其他文献中描述的数据融合所应用的各种数学方法包含了从信号处理和图像处理、统计估计方法、自动推理方法、基于知识的模式识别、模式匹配方法以及人工智能等方法。到目前为止，所开发的信息融合方法和该学科领域的主要历史事件如下：

- 贝叶斯后验概率理论发表（1763）；
- 高斯创立采用冗余数据的统计估计方法——最小二乘法（1795）；
- 统计模式识别方法的开发（如聚类分析、神经网络等）（20 世纪初到 20 世纪 40 年代早期）；
- 目标跟踪与识别的重要主动传感器——雷达的发明和探测数据处理（20 世纪初到 20 世纪 40 年代）；
- 序贯估计的卡尔曼滤波方法的开发（1960）；
- 美国空间跟踪系统开始运行（1961）；
- 面向军事应用的全源分析与融合系统的开发（20 世纪 70 年代至今）；
- 先期研究项目代理计算机网络（ARPANET）首次演示——互联网的先驱（1968）；
- 第一个蜂窝电话（手机）网络出现（1978）；



- 国家科学基础计算机科学网络（CSNET）的建立（1981）；
- JDL（Joint Directors of Laboratories，美国国防部实验室联合理事会，简称 JDL）数据融合专业组成立（20 世纪 80 年代中期）；
- JDL 数据融合过程模型的建立（1990）；
- 首次创立三军数据融合专题研讨会（1987）；
- 国家传感器数据融合年度研讨会（NSSDF）的创立（1988）；
- 第二代移动手机系统的开发（20 世纪 90 年代早期）；
- 互联网商业化（1995）；
- 国际信息融合学会（ISIF）的建立（1999）；
- 举办 ISIF 融合年会（从 1998 开始逐年举行）；
- 显现非军事应用（20 世纪 90 年代至今），包含复杂系统的状态监视、环境监视、危机管理、医疗应用等；
- 扩展到物理传感器的合作感知（20 世纪 90 年代）；
- 中国信息融合分会（CSIF）成立（2009 年）；
- 举办 CSIF 年会（已举办 8 届）。

从上述信息融合学科技术发展和重要事件沿革可以看出，该学科门类的产生和技术发展源自于应用，特别是军事应用的需求成为驱动信息融合学科发展的主要动力。随着 21 世纪的来临，信息产业和信息产品蜂拥般地出现，二战以后的以机械化和电气化为主导的后工业时代正在被信息化大潮所淹没，人类步入了信息时代。以互联网为代表的信息网络、以手机为代表的移动通信、以各类介质传感器为代表的信息收集手段和以计算机为代表的数据处理工具，正在使人类认识世界和改造世界的各活动领域在内容、方式和手段上出现了翻天覆地的变化。从 20 世纪 90 年代的新军事革命到 21 世纪初出现的网络中心战充分展露出这场信息革命浪潮对军事领域的影响，其核心是向信息和信息技术（通过信息化武器装备、信息化作战样式和信息化的人）寻求新的战斗力生成模式。信息融合学科作为人类感知世界的核心工具和人类改造世界不可或缺的主要手段，当仁不让地成为这场信息革命浪潮的助推器，它从信息收集出发，以计算机数字处理为工具，以信息网络为依托，以人一系统交互为手段，为人类构建正确认知和合理行动的信息平台。在军事领域，信息融合学科则从面向机械化战争——平台中心战的集中式融合方式向信息化战争——网络中心战的分布式融合方式迈进，从而揭开了传统集中式数据融合向分布式信息融合转变的大幕。本书对分布式信息融合面临的不同于集中式融合的挑战性问题，在概念、技术、方法和应用上进行了描述，旨在将分布式信息融合全方位地呈现给读者，作为研究、理解和应用这一前沿课题的一本指导书籍。

## 1.2 数据融合模型的概要分类

与数据融合有关的人类感知过程和信息处理过程模型有很多，文献[4]给出了对这些过程的相关考察与评估结果，其中最系统、最具代表性的是美国国防部实验室联合理事会的 JDL 数据融合过程顶层模型和心理学家 Mica Endsley 的态势感知模型，这两个模型在民用和军事

领域具有广泛的应用。表 1.1 给出了数据融合过程顶层模型和人类感知模型的概要分类，其中列出的关于各分类详细描述参考文献可以使读者对其有更深入的了解。

表 1.1 数据融合过程顶层模型和人类感知模型的概要分类

模 型	描 述	参 考 资 料
JDL 数据融合过程顶层模型	描述数据融合过程的功能模型	[2] [3] [8] [9] [10] [11]
融合的功能级	数据融合过程的各级输入—输出功能的提取, 重点关注处理的数据类型及适用于这些数据处理的有关技术	[5] [6] [7]
需求—信息处理变换 (TRIP) 模型	将瀑布式开发过程应用于数据融合, 重点在于所需信息与数据采集的连接推断	[12]
多用途模型	数据融合的自适应 Boyd OODA 环	[13]
Endsley 态势感知模型	人类态势感知的认知模型	[14] [15]
三层次模型	数据融合的三层模块化方法, 将数据集成到不同层次上: (1) 数据层 (如信号处理); (2) 证据层 (统计模型和判定); (3) 动态层	[16]
行为知识体系	基本融合阶段顺序; 从数据中提取特征向量, 配准与关联, 开发模式识别和语义标记以及把特征向量与事件连接起来	[17]
瀑布模型	表示从数据级到判定级的数据流和推理的层次结构	[18]
使用 UML 的通用数据融合模型 (DFA)	基于统一建模语言 (UML) 的通用数据融合结构模型, 使用基于数据、变量或任务定义的分类法	[19]
统一数据融合模型 ( $\lambda$ JDL)	寻求统一态势感知功能、共用作战图和数据融合等模型	[20] [21]
原始识别的判定 (RPD)	重点关注对察觉提示和行动识别结果的自然判定方法	[22] [23] [24]
观察、判断、决策、行动 (OODA) 环	基于有效观测的指挥官的军事决策过程模型, 由一些作者扩展用于通用态势估计和决策	[25] [26] [27] [28] [29]
Salerno 模型	把数据源 (按易损性进行分类) 连接到察觉、理解和预测的一个框架中	[31] [32]

表 1.1 所列模型及其排序反映了文献对它们的引用情况, 按功能可以分为两个类别, 一个是融合类, 该类偏重于描述多源数据融合计算模型和方法; 另一类是判定类, 偏重于描述基于多元信息或基于融合信息的判定模型和方法。当然, 这两类融合模型和框架并没有严格的界限。一般说来, 融合类主要面向低级数据层次融合 (信号处理和对象状态估计) 的自动计算问题; 判定类主要面向高级认知层次融合的认可与判定问题, 如目标真伪/属性识别, 态势估计与威胁判断等, 通常以人类认知与自动计算相结合的方式, 采用人机交互产生判定结果。对于描述融合过程和判定过程来说, 表 1.1 中的每个模型都有一定优势和不足, 其中带有融合功能分级的模型往往包含这两个类别的过程模型功能, 如作为典型的 JDL 数据融合过程模型, 其中的 0 级融合 (数据或原始信号处理) 和 1 级融合 (对象提取) 主要偏重于融合类, 而 2 级融合 (态势估计) 和 3 级融合 (威胁分析) 则偏重于判定类。在 JDL 融合模型中, 这两类功能既相互独立又相互联系, 通常是由融合类为判定类提供依据, 当然判定类还需要增加其他外部信息和关系信息。

### 1.3 JDL 数据融合过程模型

在始于 20 世纪 90 年代, 旨在实现军队信息化的新军事变革中, 随着多类传感器在军事

领域的广泛应用,数据融合技术快速发展,融合学界对数据融合在术语、概念、结构和算法上逐渐取得一定程度的共识,从而使数据融合成为一个独立的应用学科门类。为了使数据融合技术研究成果尽快在战场感知领域得到应用,美国国防部开始实施大规模的投资计划,建立数据融合系统,例如为美国陆军研制和装备的全源分析系统(All Source Analysis System, ASAS),正在为美国陆军战场数字化和全球反恐行动提供着有力的情报保障。

JDL 是为辅助跨越美国国防部各实验室进行合作研究而建立的一个管理团体。JDL 建立了集中关注多传感器数据融合问题的一个跨领域、跨部门组织,其正式名称是实验室联合理事会指挥、控制与通信(C<sup>3</sup>)专业组数据融合小组,简称 JDL 数据融合组。

### 1.3.1 JDL 数据融合结构模型

JDL 数据融合组于 1987 年首次建立了数据融合模型,该初始模型的顶层结构仅包含三级(对象估计、态势估计和威胁估计)<sup>[33]</sup>。JDL 在给海军情报办公室的一份简报中提出了更通用的数据融合的三层结构模型<sup>[2]</sup>:

第一层: JDL 数据融合过程顶层结构模型;

第二层: 顶层模型各融合级别的专用子过程功能模型;

第三层: 实现各项子过程功能的方法与算法模型。

经过近 20 年的发展和完善,数据融合三层结构的第一层和第二层模型演变为图 1.1 所示形式,其中第一层(顶层)结构演变为 6 级(0~5 级)。

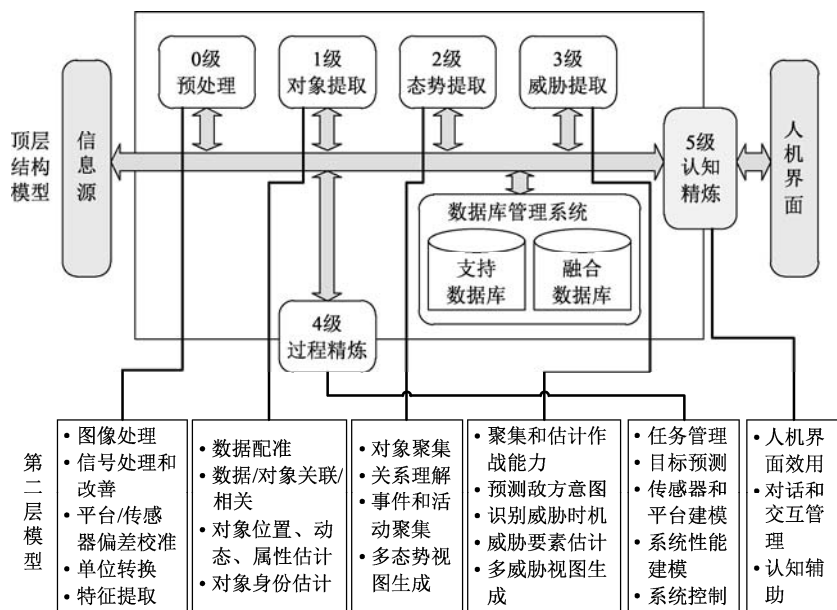


图 1.1 JDL 数据融合层次结构前两层模型<sup>[3]</sup>

由图 1.1 可以看出,数据融合的顶层(第一层)结构中各融合级别的名称和概念与融合应用特别是军事应用紧密联系在一起。顶层结构各融合级别所对应的第二层模型将各融合级别的功能内涵与采用的方法门类的功能联系起来。从中不难看出,数据(信息)融合学科的产生和发展的动力来源于应用,而采用的方法和技术则主要来源于其他相关学科。信息融合

学科对取自其他学科技术和方法的应用既促进了本学科的发展,也促进了相关学科的发展和完善。因此,信息融合实际上是一个典型的边缘应用学科。图 1.1 没有给出第三层模型即实现各融合级别的具体子过程功能的方法和算法,这是由于各融合级别采用的技术和方法的交叉性和在军民众多领域应用的广泛性,并且随着融合学科的发展,技术范围和应用领域还在不断扩展,因此第三层模型无法准确列出。文献[3]第 2 章给出的数据融合第三层模型实际上是对第二层专用子过程功能采用的方法和算法模型的进一步分解,并较详细地描述了所采用的相关传统学科门类 and 新兴学科门类,涉及概率与统计方法、优化方法、计算机、通信网络、现代控制论、人工智能、信息论、生物工程、信号处理、图像处理等。在分布式信息融合中,由于含有局部与全局效用的协调、代理之间的合作选择、信息资源优化分配、信息分发优化路径等问题,因此融合算法涉及社会、经济、军事、人文等众多学科,如军事运筹、拍卖机制、合同信誉估计、人一代理集合体(HAC)等技术和方法。

### 1.3.2 JDL 顶层融合模型的演变

从图 1.1 可以看出,JDL 数据融合顶层模型在融合结构的发展中起主导作用,自 1987 年第一个 JDL 数据融合顶层模型出现后,近三十年来,JDL 顶层模型不断补充、修订和完善,在其发展和演变的过程中,以下 6 个顶层模型具有一定代表性:

- 1987JDL 初级模型<sup>[33]</sup>,由 White、Hall、Llinas 等人建立,含有 1~3 级:对象估计、态势估计、威胁估计,主要针对军事应用。
- 1998JDL 修订模型<sup>[34]</sup>,含有 0~4 级,由 Steinberg 等人提出,增加传感器级(0 级:信号处理或子对象处理),并将过程精炼作为第 4 级;将 JDL 模型应用扩展到军事领域之外。
- 2004JDL 推荐模型<sup>[35, 36]</sup>,含有 0~4 级,由 Bowman 等人提出,将 4 级融合过程精炼改为过程评估,将 4 级融合中的优化控制列入资源管理,但将资源管理和数据库管理置于融合范围之外,这反映了传统融合学界强调自动融合、减少人的作用的观点。
- JDL 融合过程顶层模型<sup>[3]</sup>,含有 0~5 级,由 Hall 等人于 2004 年提出,他们针对当时力图摆脱人的自动数据融合与信息化战争的战场感知需求渐行渐远的趋势,对 2004JDL 推荐模型进行了较大修正,从而确定了迄今为止为融合学界公认的包含有人参与的第 5 级融合(即认知精炼)的 6 级结构模型。
- DFIG2004 模型,又被称为数据融合信息组模型<sup>[35]</sup>,是 JDL 数据融合组部分专家从“复兴”融合学科观念出发提出的,含有 0~6 级,其将人起主要作用的融合管理(资源管理、任务管理)纳入融合范畴作为第 6 级,为进一步确定人在融合中的主导作用奠定了基础。
- 用户—融合模型<sup>[11, 17, 38]</sup>,含有 0~5 级,该模型明确给出了第 5 级融合用户精炼对 0~4 级融合的信息支撑关系,从而成为人作为信息融合主导者的 JDL 顶层模型的典型代表。

图 1.2 给出了信息融合顶层模型演变过程和两代融合系统的主要特征。

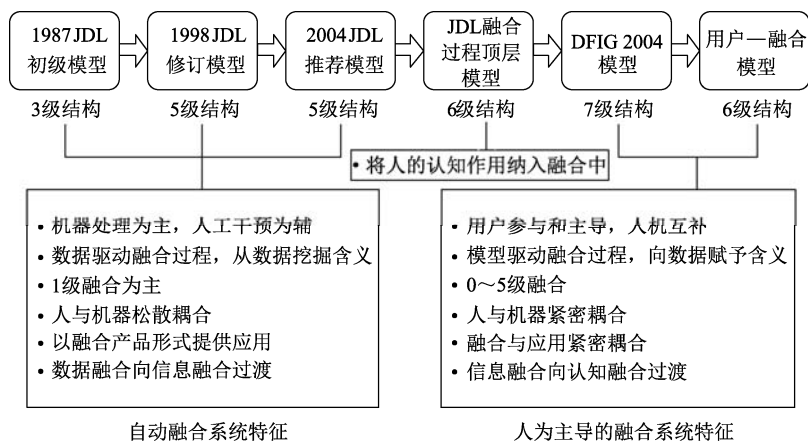


图 1.2 JDL 信息融合顶层模型演变及两代融合系统的主要特征

从图 1.2 可以看出，JDL 信息融合顶层模型正在从传统的自动融合系统（第一代）向以人为主导的融合系统（第二代）演进，这反映了信息时代人在感知中的作用正在逐渐增强。图 1.2 所列出的两代融合系统特征展现了两种感知观点：第一种观点认为人是感知主体，传感器和各种感知技术手段是对人类感官的扩展；信息融合学科研究内容来源于应用活动需求，通过寻找所需要的适宜数据和证据支撑而进行信息获取和信息处理；在技术实现上，用户基于需求设计感知模型，以模型驱动融合系统运行，寻找与模型匹配的数据，即向数据赋予含义和知识，再经逐级融合，产生满足应用需求的态势信息；在融合模式上，该观点认为用户要与机器紧密耦合；在管理上则认为用户需要进行融合系统立项、论证，并参与系统设计、开发，以及运行交互控制和信息分发活动；总之，必须充分发挥人的认知能力在融合活动中的作用，否则无法产生满足应用需求的信息产品。第二种观点认为机器（传感器、通信和计算设备）是感知主体，人类的认知行为开始于数据，即传感器观测输入，再向上推进到为人类应用活动服务；在技术实现上，该观点认为以数据驱动系统运行，从传感器数据中提取特征、关系和知识，并构建应用模型或直接提供用户进行应用选择；在融合活动模式上，该观点采用机器在后台自主运行、自动进行融合处理的模式，在前台的界面上显示融合结果供用户干预选取。

从以上分析不难看出，第一种感知观点反映了人的认知能力在感知中的主导作用正在增强。第二种感知观点反映了电子/信息设备的感知应用范围的扩大和效能提升。然而，信息融合学科的产生和发展皆离不开应用，特别是从信息时代人类感知领域的扩展和感知效能提升对信息融合的需求进一步深化的观点来看，基于人作为感知主体的第一种观点更容易实现人与融合系统的紧密耦合以及融合与应用的紧密耦合。由于感知行为属于认识世界范畴，而感知的目的在于改造世界，感知技术和手段则是人类为认识世界和改造世界创立的，信息融合的硬/软设施与技术概出于此，因此，以机器为主体的第二种观点在理论上是站不住脚的。尽管在融合学科产生和初步发展的 20 世纪，机器和设施（硬、软设施）曾在数据融合中起到过重要作用，人们曾幻想建立一个独立的自动化学科，甚至迷信人工智能的发展能够取代人的认知作用。但随着 21 世纪信息时代的来临，信息产品和信息化设施正在改变着人们的生活，并使人的观念产生重大变化，但是人在认识世界过程中的主导作用没有改变并且日益

凸显,图 1.2 显示的 JDL 信息融合顶层模型的演变充分说明了这一点。目前正在出现一些新的人与机器相结合的融合体系结构,在人的主导下,充分发挥用户的认知能力以及机器(含网络)的计算与信息传输优势。总的看来,建立信息时代的融合结构模型还任重而道远。

### 1.3.3 JDL 融合顶层模型的主要功能

我们以图 1.2 所示的 JDL 融合顶层模型演变中由自动融合系统向人为主导融合系统过渡的 JDL 融合过程顶层模型(见图 1.1 所示的顶层模型)为典型代表,描述 JDL 顶层模型主要融合级别及其功能。

Hall 等人在 2004 年提出的 JDL 顶层模型定义的 6 个融合过程概述如下:

0 级融合(数据或源预处理)包含处理来自传感器的数据(如信号、图像、高光谱图像、矢量分量或标量数据)及为后续的融合准备数据。数据预处理的例子包括图像处理、信号处理、数据“整理”、坐标变换(把来自探测点或传感器平台的数据变换到一个中心坐标系中)、观测数据时空校准、信号或数据滤波以及格式变换、单位变换等。0 级融合最终实现单/多源信号融合目标检测。

1 级融合(对象提取)组合来自多传感器或信息源的数据,以获得对象定位、特征和身份的可靠估计。术语“对象”通常用来表示物理对象,如飞机、舰船、车辆或人。然而,我们也可以通过数据融合确定活动、事件或所关注的其他受地理约束的实体的位置和身份。对象/实体定位(估计)问题通常与对象/实体识别问题分别讨论。然而,在现实的融合系统中,则将这些子过程集成到一起。

2 级融合(态势提取)利用 1 级融合的结果和外部信息,开发出它们的关系(contextual)含义说明。包括怎样理解实体与其所在环境的关系、不同实体之间的关系以及它们怎样相互关联。例如,在一个环境中车辆的运动状态可能取决于道路、路况、地形、天气及出现的其他车辆等诸多因素。人群中的一个人的行动与其四周没有其他人的情况可能有完全不同的解释。用于 2 级融合的技术包含人工智能、自动推理、复杂模式识别、基于规则的推理及许多其他方法。

3 级融合(威胁提取/影响估计)包括通过当前态势预测未来,以确定潜在的影响或与当前态势相关联的威胁(即对我方不利的影响)后果。3 级融合寻求对可能的威胁、对觉察到的威胁的响应行动,以及对察觉的态势变化可能导致出现威胁的新情况等推断。3 级融合技术类似于 2 级融合。

4 级融合(过程精炼/资源管理)寻求改进融合过程(更精确、更及时和更具体)。这要通过改变传感器或信息源的指向、改变融合算法的控制参数,或选择更适合于当前态势、当前数据的处理算法才能实现。4 级融合包含的功能有传感器建模、网络通信建模、性能度量计算,以及资源利用的最优化等。

5 级融合(人一机交互/认知精炼)探索数据融合系统与人类用户怎样互动才能达到最优化。5 级融合寻求理解人类用户的需求,并且通过使融合系统合理地集中关注用户的最重要事情来响应这些需求。如图 1.2 中作为以人为主导的 JDL 顶层模型典型代表的用户融合模型<sup>[37]</sup>,其中的 5 级融合用户精炼是为各级融合提供用户最关注的重要因素:对 0 级提供融合

系统所需要的数据价值，以使其优先收集最有价值的数据或进行数据优先排序；对 1 级融合提供关注对象的优先级，使其优先处理最关注对象；对 2 级融合提供周边关系信息 (Contextual)，以提升态势估计的准确性，减少不确定性；对 3 级融合提供敌威胁意图信息，这是用户基于其他顶层、外部或环境，信息渠道获得的，以提高威胁估计的正确性；对 4 级融合提供融合系统要达到的效用（尚存在的效用差距），作为过程精炼控制的依据。采用的技术手段和工具包括采用先进的显示手段、搜索引擎、咨询工具、认知辅助、合作工具及其他技术。其中包含使用传统的 HCI 功能，如地图显示、数据和图层显示、处理输入命令以及使用非可视界面如声音或触觉界面等。

JDL 模型的创始者们充分认识到 JDL 级别是对数据融合功能的人为划分，并且这些级别是相互重叠的。在实际系统中，融合并不是以序贯方式（0 级、1 级、…）实现的，这些过程是交织在一起的。例如，在 1 级融合中，从一个目标的运动信息能够洞察目标的身份和潜在的威胁（3 级）。然而，数据融合功能的这种人为划分已被证明是有益的。

## 1.4 Endsley 态势感知模型

图 1.3 给出的 Endsley 态势感知模型是面向人类完成某项任务的感知过程，该模型的目标是将认知任务因素（如要实现的系统能力、界面设计、压力与负荷、复杂性与自动化等）与支撑该认知任务的各独立特征因素（如目标和对象、察觉（预期）结果及基于能力、经验和训练的信息处理机制等）联系起来。为实现这一点，该态势感知模型从人的感知心态出发，将感知过程分为当前态势元素察觉、当前态势理解和未来态势预测三个认知阶段，并将态势感知结果与该认知任务的判定和行动环节集成到一起。

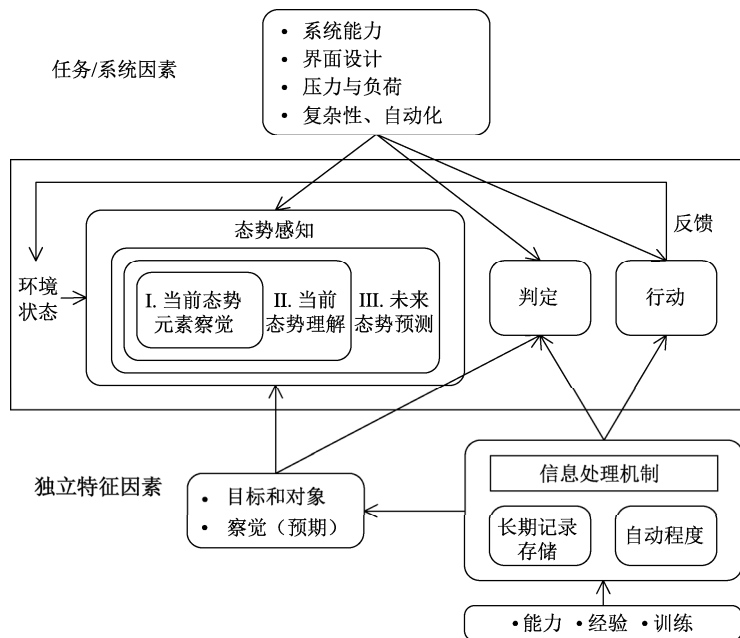


图 1.3 Endsley 态势感知模型



图 1.3 所示的 Endsley 态势感知模型展现了完成认知任务的态势感知过程，与作为数据融合典型代表的 JDL 模型有着惊人的相似之处<sup>[30]</sup>：

- 其中的一级感知（态势元素察觉）与 JDL 模型的 0 级和 1 级融合相对应，其目的都是对感知环境和对象元素进行提取（状态和属性估计）；
- 二级感知（态势理解）与 JDL 模型的 2 级融合（态势估计）相对应；
- 三级感知（态势预测）与 JDL 模型的 3 级融合（威胁估计）相对应，因为威胁估计实际上是预测的未来态势对己方可能产生不利影响的估计；
- 该态势感知模型中的判定框功能体现了对前三级感知结果是否满足认知任务需求的判断和估计，这正是 JDL 模型的 4 级融合（融合过程精炼）所进行的过程评估，为融合过程各级别的功能调整提供依据；
- 该态势感知模型中的行动框功能体现了人对感知过程的控制与管理，是人对前面几级态势感知（JDL 的前面级别的融合）结果的认定之后产生的，所以与 JDL 模型中的 5 级融合（认知精炼）相对应。

值得指出的是，Endsley 态势感知模型与 JDL 数据融合顶层模型各级别的对应关系并不严格，如三级感知的态势预测与 JDL 模型的 3 级融合（威胁估计）并不直接对应，又如态势感知模型中的判定框和行动框皆包括人的认知能力，因此都与 JDL 模型 5 级融合有关。

Endsley 态势感知模型更重要的价值在于其可以将人类认识世界的态势感知任务扩展到改造世界的活动任务之中。在军事领域，Endsley 态势感知模型可以从战场感知领域扩展到作战领域，即其可以涵盖作战行动的所有环节。此时，态势元素察觉、当前态势理解和未来态势预测属于感知域，而判定和行动属于作战域。其中判定是指挥员基于态势感知和作战任务所进行的作战决策，如确定意图、定下决心、生成方案（计划）等活动；而行动则指各作战单元按作战决心和方案/计划实施的作战活动，如兵力集结、展开、交战及评估等。

不只是 Endsley 态势感知模型，面向态势感知的 Boyd 观测—判定—决策—行动（OODA）环模型在应用上同样能够从认识世界的感知域扩展到改造世界的活动任务域之中。文献[32]较深入地分析了人在战场感知 OODA 环中的作用，特别是在情报对抗环境中，对伪装、隐蔽和欺骗（CC&D）手段的识别与控制及其在 OODA 各环节中的体现进行了详细的描述，将 OODA 环模型在军事领域的应用扩展到整个作战任务中，其中前两个环节（观测与判断，OO）属于战场感知域，即对未知的态势要素的察觉、判断（理解）的过程；而后两个环节（决策与行动，DA）属于作战域。与 Endsley 态势感知模型的应用扩展类似，此时的“决策”是指挥员基于态势感知结果和作战任务所进行的作战决策活动，而“行动”指各作战单元按作战方案和计划实施的作战行动；这里的决策和行动显然也包含对 CC&D 手段的运用和识别。

## 1.5 影响信息融合学科发展的相关动向

信息融合学科的产生和发展来源于人类在认识世界和改造世界中的应用，并且其采用的技术和方法主要来源于其他相关学科。因此，偏离应用将使信息融合学科没有生命力，而如果不理解信息融合学科的边缘性特征，会使信息融合学科无从发展。21 世纪对信息融合技

术的发展提出了大量应用需求,同时各信息技术(IT)门类的产生和发展以及人类观念的信息化更是为信息融合学科的发展提供了持续的动力。在当前已步入的信息时代,信息融合学科发展面临的信息技术(IT)背景如下:

- ① IT本身的快速发展和变化的信息技术;
- ② IT正在冲击可能产生的个体和社会变化;
- ③ IT影响着全球问题产生的原因和解决方法。

在IT背景下,影响信息融合学科发展的相关信息动向有:信息技术(IT)、信息效用和受其影响的人类观念的变化,分述如下:

信息技术(IT)——IT正在高速发展,从借助先进的传感器和人工观测所进行的随处、持续的全球监视到日益增加的可移动计算设备(移动电话、嵌入到日常装置中的“无形”计算机、网络书刊、笔记本电脑等),遍布的网络连接具有日益增加的访问速度,并且借助多(人)传感器输入,人机界面得到了大大的改善。这就导致人们之间近乎全球地连接。在web上的数据海啸以及虚拟访问的无限计算能力,这些变化正冲击着人们的生活和事物的各个方面,也必然改变数据融合系统的概念和实现方法。表1.2提供了影响融合学科发展的信息技术在关键领域的动向举例。

信息处理——借助传感器和人工输入所产生的有效数据(包含信号、图像、视频和文本)大量增加,成为对存储、访问、归档、分发、元数据生成及数据谱系等信息处理问题的主要挑战。人类关注单元(人访问的数据量和他们对数据的有限关注能力)的极限将导致人—数据互操作的机遇和挑战。表1.3概述的关键信息领域包括数据归档和分发、元数据生成及硬软数据的融合。

人类观念的变化——最终,IT的变化和信息的可用性导致人类行为和期望的变化。网络一代人(30岁以下的年轻人)总是使用互联网、手机、计算机及有关技术。这些“数字人”在解决问题、搜集和共享个人信息以及建立分布式社交网络的途径等方面展现出不同的方式。这就依次影响到教育、合作、商业和信息安全等问题。表1.4概括了新一代“数字人”产生的潜在影响和显露出来的参与意识对融合学科的影响。

表 1.2 影响融合学科发展的信息技术动向举例

领 域	动向和问题
数据收集	<ul style="list-style-type: none"> <li>无处不在、持续不断的监视: 现在已出现对全球范围无处不在的持续监视系统。如国家信息收集系统、长航时无人空中飞行器(UAVs)等,基于离地和在地传感器提供多频谱、多模态的<math>24 \times 7</math>基线的监视机会。这就能够对几乎任何关注的区域进行集中和不间断的监视。出现的挑战性问题是怎样处理巨大的数据雪崩,包括对这些数据进行分类,发现有用/关注的信息,并生成有意义的知识。这样的监视影响着很多领域,例如环境监控,了解疾病的分布和蔓延状况及犯罪和恐怖主义等。</li> <li>新的传感器和感知模态: 物理传感器的不断改进,催生了新的观测模式,包括增加了嵌入式信号和图像处理能力,在操作控制上增加了智能模式,并对传感级数据处理不断进行改进,如语义元数据生成、模式识别、动态传感器性能特征化、目标跟踪及自适应处理等。</li> <li>开源信息: web站点能够处理所搜集到的各种类别信息,例如,基于报告和标绘手段的站点(ushahidi.com)能提供危机事件、政治暴乱等信息。谷歌街景视图(Google Street View)能提供世界上许多地点的地面全景照片形式的地图。图片共享站点flickr(flickr.com)包含1000多万主动贡献者提供的超过50亿张的照片。商业数据提供者如Digital Global站点(digitalglobe.com)还能提供卫星图</li> </ul>

续表

领 域	动向和问题
数据收集	像访问, 包括标准光学图像、立体图像及 8 波段频谱图像。有关气象信息、环境数据、细化地图、视频监控、交通监控及许多其他类型的信息都能够很快得到
移动计算	移动计算能力在功能、存储、速度和网络互联能力等方面迅速增长。新的智能手机具有典型规格, 包括 4~16 GB 存储 (可扩展到 32 GB), 1~1.2 GHz 范围的处理速度, 具有第 4 代通信速率及 480 × 800 像素到 960 × 640 像素的手触屏。已经开发了超过 100 万个开源应用。这些都导致了便携式计算/感知/通信装置迅速扩展到全世界
网络速度和连接性	互联网的连接正在接近无处不在。60 Kb/s 地面电话的原始连接方式改变为 4~6 Mb/s 典型速率的电视同轴电缆或光纤连接, 借助地面移动电话网上的移动宽带网增加了移动连接, 以及市区中的 WiFi 热点和卫星互联网连接。美国曾一度落后于某些国家, 这些国家已提供了百兆速率连接到家庭。移动设备越来越借助移动互联网共享和访问视频数据, 并将视频数据扩展成为移动互联网数据内容的支配者。网站 zakon.org 提供了互联网发展历史的概述
云计算	云计算将计算资源当作一项产品 (网络共享资源和信息), 类似于电气网格的概念。互联网无处不在的能力使得计算资源 (大数据存储、复杂计算模型、大规模计算能力等) 能成为任何人的指尖收费资源。最终, 随着所提供的空前的访问能力, 该概念将淘汰局部 IT 工作人员和计算机。一个典型的例子是 Wolfram Alpha (wolframalpha.com), 它能提供对大数据集和复杂的物理与数学模型的自由访问
人机界面	HCI 的进步包含日益增加人访问数据的能力和多 (人) 交互感知手段逼真度。例子有使参与者全浸入的 3 维界面和语音 <sup>[39]</sup> , 能够进行视觉和听觉模式识别, 触觉界面能提供触感。还可能需要建立新的多介质感知手段、全浸入界面能够充分与人的混杂能力打交道, 进行模式识别和异常检测

表 1.3 影响融合学科的信息处理动向举例

领 域	动向和问题
数据归档和分发	正在爆发的数字宇宙: 根据 2010 Gartner 报告, 大企业的三个顶层挑战是数据增长以及随之出现的系统性能和可测量性 <sup>[40]</sup> 。在 2007 年, 该数字宇宙已达 $2.25 \times 10^{21}$ 比特 ( $281 \times 10^{18}$ 字节), 到 2011 年, 估计会增长 10 倍。最快速增长的数据源包括数字 TV、监视摄像机、传感器应用, 以及社交网络。主要问题是怎样存储、归档、分发、访问以及怎样表示这些数据 (Chute 等人) <sup>[41]</sup>
元数据生成	借助物联网 (Internet of Things) 和人类的数据收集活动, 收集和存储了海量数据 (信号、图像、视频), 面临的挑战性问题是怎样表示这些数据, 以便于后续的检索和使用。重大的进步是通过对信号数据和视频数据的预期扩展, 产生画面的自动语言提示 (即由机器生成语义标记)。这就能够借助正出现的先进搜索引擎 (即下一代 CITESEER 型引擎 [citesee.ist.psu.edu]) 提供访问信号、图像和视频数据的功能
硬与软融合	在数据融合研究中出现的一个新领域是硬 (传统物理传感器) 数据和软 (人的观测) 数据的融合。该题目在 2009 年 2 月首次在由多传感器信息融合中心 (CMIF) 主持召开的 Berver Hollow 研讨会上进行了讨论 (见 infofusion.buffalo.edu)。该研讨会探讨了硬和软数据融合; 来自人的源数据表征、结构问题以及硬与软融合术语的最基本定义。从该会议以后, 国际信息融合学会 (ISIF) 召开的 FUSION2010 年会和 FUSION2011 年会都安排了关于硬与软融合专门议题

表 1.4 影响融合学科的人类行为变化动向举例

领 域	动向和问题
数字人 (Digital natives)	网络一代: 他们使用互联网、手机、社交网络、全球连通、立即可用的在线资源, 有着与上一代人 (见 Tapscott2009) <sup>[42]</sup> 大不相同的社会观念和认知方法, 历经 30 年产生的当今 “网络一代” 人 (族) 已经成熟。这些 “数字人” 对商业交往和解决对社会各方面有重大影响的问题中的每件事具有不同的期望值。文献 <sup>[43]</sup> 描述了新的合作时代的某些含义, 其将导致关于世界大百科全书 (wikipedia*—合作环境网站)、共用商品软件、PatientsLikeMe (容许连接)、Ushahidi 及其他动态合作意图的一些规划项目
合作感知	合作感知: 一些发展情况和动向提供了建立一个新的、世界范围的数据收集资源的机会, 包括: ①遍布世界的与日俱增的智能手机; ②智能手机的处理能力和传感器插件 (包括高清摄像、视频能力、环境传感器等) 的增加; ③数字一代人的出现 <sup>[44]</sup> , 他们借助推特 (Twitter)、脸谱 (Facebook) 和其他社交网站收集信息并共享专用信息。这将导致合作感知的概念, 其中个人和群组主动合作进行从犯罪预防到科学研究等各领域信息收集

## 1.6 信息时代对分布式信息融合的需求

信息融合学科的边缘性和信息融合技术与应用的紧密耦合性使得 1.5 节所描述的当前信息技术、信息处理及人类观念和行为等领域的巨大变化,正在冲击并持续影响信息融合技术的发展和信息融合系统的设计与实现。我们基于上述影响信息融合学科发展的相关信息动向分析,无论从信息社会的需求还是从技术支撑的可能性上看,分布式融合模式都将成为信息融合学科发展不可逆转的趋势。

自然界(包括人类)的生存活动遍布世界各时空角落,因此人类认识世界和改造世界从集中式的点(局部)扩展到分布式的面(全局)是生产力发展的必然规律。自 20 世纪 70 年代以来电子/信息技术的飞速发展和应用,特别是无处不在、随时可用的高速网络、传感器和手机雪崩式地增加以及日益增长的移动计算、云计算与大数据等,催生了经济全球化,并且正在改变着人的观念(产生一代数字人)。在人类感知领域则大大促进了集中式认知向分布式认知的转变,这就需要将传统信息融合技术、设计实现方法扩展到分布式应用环境中。信息时代对分布式融合的需求包括以下 5 点。

### (1) 分布式融合结构

分布式信息融合结构涉及的因素首先是分布式应用即网络中心应用需求<sup>[45]</sup>,如在军事应用的网络中心战(NCW)中,各级多作战单元的战场感知、指挥控制与火力打击需求<sup>[46, 47]</sup>;其次是感知环境(干扰、杂波和噪声)对融合信息的影响;第三是基于信息效用的网络节点连接;第四是传输带宽产生的信息到达时间延误和误码率;以及第五,考虑信息源相关和非相关的融合算法等。基于这 5 个因素的分布式信息融合结构样式包括<sup>[46, 8, 49]</sup>:

- 多层次分布式融合结构;
- 单一层次分布式自主融合结构;
- 单连接和多连接融合结构;
- 有反馈、无反馈和部分反馈融合结构。

当前分布式结构有两个发展趋势。第一是单一层次(同级)自主式融合结构,正向自组织和自同步结构发展,主要体现在 JDL 顶层结构模型的第 4 级过程精炼、第 5 级认知(用户)精炼(可能还包含 DFIG2004 模型的第 6 级感知资源和任务管理)中的自主控制,以满足网络中心战非线性、非对称、非理性作战需求<sup>[50-52]</sup>。第二个发展趋势是多层次信息融合结构正向两端扩展,向上端扩展是指扩展到战略级信息融合,以适应国家和全球等顶层领域综合态势和发展战略及路线图的评估需求;向下端扩展是指扩展到最底层战术行动层次,以使融合领域的多层次、多应用效能达到整体大于部分之和的效果。

### (2) 分布式态势感知

分布式态势信息获取是指对时空分布配置的多信息源(传感器、探测平台、人工情报源等)基于自身的特征对态势信息的自主协同和合作获取方式<sup>[53]</sup>,以基于需求获得低风险(少虚警和漏警)、完备、有序的态势信息。

当前,分布式感知面临的特殊环境包括弱信号环境(隐身、强干扰、目标机动等)、面向火力协同的多平台全分布环境、战区与战略态势估计中的全谱感知环境以及非统计独立的多源相关信息环境。

分布式感知依赖的因素有:

- 信息源的合作与表征;
- 开源信息的表征与可信赖性;
- 异类介质信息的统一表征与转换;
- 自适应信息谱系和信赖性;
- 信息源(传感器)元数据自动生成;
- 全维空间感知平台与传感器入网与信息流向控制。

### (3) 分布式融合算法

分布式融合算法是不同于传统集中式融合的新的信息处理算法,这些新算法来自基于网络连接分布式感知环境、分布式处理环境和分布式分发应用(服务)环境。

分布式融合算法包括如下几类:

- 多传感器分布式目标检测算法<sup>[54-56]</sup>;
- 弱信号目标协同检测与跟踪算法<sup>[58-59]</sup>;
- 基于相关信息(重复计入信息)的融合估计算法<sup>[57]</sup>;
- 基于效用的信息传输路径与带宽分配算法<sup>[62]</sup>;
- 多自利平台的全局协同算法<sup>[60, 61]</sup>;
- 基于信用的合作代理选择算法<sup>[63, 64]</sup>。

当前信息领域正在出现的云计算和大数据能力能够为这些分布式融合算法提供有力支撑。

### (4) 分布式智能

分布式智能旨在感知域融入人工智能和人的智慧,以发挥人,特别是用户的认知能力在感知中的作用。主要面向信息融合的2级态势估计和3级影响(威胁)估计,即高级融合范畴。在前面所述的JDL最新数据融合顶层模型中的第5级中,用户精炼能够充分体现人的智慧对信息融合整体功能和效用的影响。分布式系统面临的感知环境有两类,一类是传统的理性、线式和符合逻辑的变化环境,这是符合人类传统认知的判断与决策环境,当前人类已认识的事物,如对抗政治、经济、金融、军事等领域有规律的认识概莫如此;另一类是非传统的非理性、非线性和非逻辑变化环境,这是人类尚未认识和正在认识的判断与决策环境,其中存在众多的不确定性,如对抗环境中的伪装、隐蔽和欺骗(CC&D)行为<sup>[65]</sup>及当前世界面临的恐怖主义行为等。

感知领域的分布式智能在内涵上分为两个层次,第一个层次是指人的智能认知分别对各融合层级和节点代理自利行为的抑制,使各代理不至于过度地将局部需求置于首位。第二个层次是人的智能对整体感知效能的主导作用,通过对各代理利他行为和全局考量的支撑、精炼、综合与实现,使整体感知效能满足全局应用需求。感知域的分布式智能又称为基于智能的分布式融合模式。这两个层次的分布式智能融合的主要问题有:

- 机器与人的语言和语义的统一数字化表示，以在人机界面上实现人与机器的一致理解<sup>[68]</sup>；
- 软/硬数据融合，这是指机器数据与人的理解、判断信息的融合；
- 人—代理集合体（HAC），这是指计算代理与人的一系列交互合作关系<sup>[66, 67]</sup>；
- 智慧交互，这是指实现多人基于知识的推理，基于灵感、联想性思维和不假思索的判断等认知能力的交互融合；
- 非常规环境中的智能判断与决策模型。

#### （5）分布式应用

分布式应用又被称为分布式应用融合模式。该模式的目标是使分布式多级多用户融合产生的整体（全局）效用达最大。为了实现这一点，要将分布式多级多用户应用效果信息纳入融合系统之中，融合系统通过对各信息应用效果的局部和全局评估，对感知资源、融合结构和融合算法进行过程精炼和认知精炼。分布式应用融合模式充分体现了信息融合学科与应用领域的紧密耦合性，同时也为探索和评估影响重大事件的多领域因素的效能提供依据。例如对地缘政治因素、民族宗教因素、阶级斗争因素、民主体制差异及经济发展因素进行融合分析，基于分析结果抑制不利因素，增强有利因素，这样才能预先防范局部冲突和恐怖主义的出现。在网络中心战中，在网络和卫星导航系统支持下，多平台作战单元对重要威胁目标（如弹道导弹）进行不同时间、不同地点、同时到达的协同火力打击需要对各平台火控探测信息、弹地通信信息和预先风险信息进行融合评估，基于评估结果对各平台射击诸元进行优化控制和调整，以提升分布式协同打击效果。分布式融合顶层应用面临的主要问题有：

- 基于大数据的多领域、多因素战略态势与发展路线图研究；
- 全谱作战中的征候、态势与威胁分析；
- 探测/融合信息向武器平台的无缝交接技术；
- 运动平台探测误差的可观测性和能控性技术；
- 基于应用特征和应用效果的融合评估与分布式控制模型。

## 1.7 分布式融合面临的主要挑战

基于 1.6 节所描述的信息时代对分布式信息融合学科的 5 类需求，能够分析和概括出分布式信息融合学科当前面临的以下 6 个主要挑战。

#### （1）网络中心战需求的挑战

1.6 节描述了信息时代对信息融合的 5 方面需求，在理论上是正确的，但从军事应用角度来看并不十分准确，即与当前的网络中心战的耦合并不紧密。这场新军事变革产生的网络中心战在技术上向信息和信息技术寻求新的战斗力生成模式，在行动上则向联合和协同作战模式寻求新的作战能力提升<sup>[69, 70]</sup>。然而，仅基于 20 世纪 90 年代以来的几次局部战争和反恐行动尚无法确定网络中心战的具体作战样式。已总结出的非对称/非线式/非接触作战、自组织/自同步作战、斩首行动/防区外发射、远程精确打击、舆论战/心理战/法律战以及全谱作战

等样式,基本上都处于具体行动层面上。这些作战行动样式对分布式信息融合有一定的具体需求,但并没有体现和提炼出网络中心战对信息融合学科理论、技术和方法的整体发展需求<sup>[71]</sup>。当前世界各军事强国都在争相参与局部冲突和全球反恐行动,旨在寻求网络中心战的具体作战样式,其中,驱动战场感知领域需求向系统化演进,实现融合学科从集中式向分布式转变是其目的之一。

### (2) 分布式融合结构的挑战

基于网络连接的分布式融合系统,既面临各作战节点的局部需求,又面临多级多节点作战系统的全局需求。因此,分布式融合结构应寻求全局融合与局部融合在功能上的平衡或优化,并且该平衡结构要根据需求的变化进行动态调整。对分布式融合功能产生影响的因素包括网络带宽、信息流向和流量、层次融合的信息反馈、过程噪声、相关信息融合算法选择及信息效用等诸多因素。因此分布式融合结构应在诸因素约束下寻求占用资源最少、信息效用最大,并能够满足作战用户动态需求的融合结构。当前已展现出的各种分布式融合结构(本书第4章和第6章所述)基本上是基于具体应用需求设计出来的,其优化具有相对性,对分布式融合结构的研究成果在理论上尚不完善。

### (3) 新概念和新方法的挑战

分布式信息融合网络含有三类节点:信息源(传感器)节点、信息处理(融合)节点、信息用户(服务对象)节点。在网络支撑下,这三类节点协同运行,实现信息效用的最大化,这是分布式信息融合系统的最本质特征和要到达的最终目标。这就使得分布式的多层次、多节点融合与集中式的单一节点融合相比,产生了许多新概念和新方法。首先,集中式融合中各种信息源相互独立的假设不再成立,不同时间到达信息之间的独立性假设也不再成立。在分布式融合中,这两个信息关系假设不再成立称为信息之间具有相关性,该相关性的概念与集中式融合中的相关概念完全不同(集中式融合中相关概念与关联概念类似),从而导致了許多新方法的出现。第二,分布式融合结构(信息图)通常会产生共用节点,该节点信息会在某下游(局部或全局)节点重复计入,其产生的相关性会导致融合误差协方差增长。为避免这一点,在融合结构上可采用局部重启或全局重启(即只采用两次通信之间的一段航迹测量)方法避免信息重复计入。第三,传感器协同问题,即对各传感器进行探测任务(范围或目标)协同分配并向信息融合节点协同分发,以通信带宽为约束,以信息效用达最大为目标。第四,自利平台的协调问题,由于各信息处理平台节点以满足其服务的局部应用节点需求为第一目标,其自利行为会与全局信息效用冲突,这就需要在各自利平台效用与全局效用之间进行调整,以全局信息效用为第一目标,鼓励具有全局理念的平台,惩罚直到去除极端自利平台,以全局(兼顾局部)优化为目标分配感知资源,以满足应用任务对感知的需求。第五,多类服务代理的信用估计问题,基于服务合同完成情况报告,估计异类一揽子服务合同完成的后验概率及其协方差,作为融合代理选择合作对象(传感器和其他融合代理)的依据,以合作获得最大的信息效用。

### (4) 新算法的挑战

针对分布式信息融合新概念和新方法的挑战,已陆续出现了许多不同于集中式融合的新



算法。首先是将集中式融合的优化算法,如极大似然估计,极大后验估计和极小方差估计等算法推广并解决分布式融合面临的新挑战问题,如将贝叶斯估计算法推广到去除信息重复使用,以控制由于信息相关导致的融合误差协方差增长;小航迹(Tracklet)融合算法通过解除信息之间的相关性使分布式融合可以使用集中式融合算法。此外,还出现了许多分布式融合的尝试性(启发性)方法,如在信息相关性未知、隐式已知或部分已知情况下所采用的有界协方差增长(Bounded Covariance Inflation, BCI)算法、协方差交集(Covariance Intersection, CI)算法及指数混合(Exponential Mixture)加权算法,通过增大误差协方差椭圆边界或调整融合权值去除信息之间的相关性。近年来出现的基于有限集统计学(Finite-Set Statistics, FISST)的概率假设密度(Probability Hypothesis Density, PHD)滤波和基数化(Cardinalized)概率假设密度(CPHD)滤波为集中式单目标跟踪扩展到分布式多目标跟踪提供了近似实现算法<sup>[78-80]</sup>,尽管该算法目前只限于多目标的泊松分布和独立同分布聚类这两类随机分布过程,并且在计算实现上具有一定难度,但对分布式多目标跟踪提供了不同于贝叶斯滤波从单目标向多目标扩展的另一个思路和实现途径,目前正处于发展和完善之中。

#### (5) 人参与感知的融合挑战

基于信息融合的产生、发展和应用与用户的紧密耦合性,有人参与和主导的信息融合是融合学界从盲目追求自动化的低级融合迈向以人为中心的高级认知融合的一个重要发展方向,这使得分布式融合面临人在感知环中的一系列挑战性问题。首先是高级融合中的语义挑战问题,其涉及以人为主导的2、3级融合(JDL顶层模型中的态势估计与威胁估计)中的知识表示、统一基准、一致理解和语义谱系的正则化。当前各国的信息融合专家采用的高级融合语义表示可谓五花八门<sup>[81-84]</sup>,因此,为了实现人与机器语义的一致理解以及多节点高级融合中的决策者对态势的一致理解,语义挑战成为了需要首先解决的问题。第二是认知挑战问题,其涉及多节点决策者面对意料之外的态势的认知思维方式与可能出现的判断结论之间的关系表述,特别在应对非理性、非线性和非逻辑态势和事件的多人协同决策中,认知挑战成为不可回避的问题。第三是人—系统交互挑战问题,该问题是以用户应用为主导的融合系统实现人机交互运行的关键技术,在网络为中心的分布式感知系统中,多节点人—系统协同交互更是成为全局优化感知与应用的关键技术。该挑战性问题包括人—系统交互约定关系和人机交互界面。其中交互约定关系包括人机约定关系和多节点多人约定关系,美国、澳大利亚和加拿大的融合专家虽然都采用联合分布式信息融合试验床(CDIFT)作为共用基础设施,但采用的人机交互规则、协议和模型各不相同<sup>[85-91]</sup>,因此,统一人—机交互约定关系并建立多节点多人—系统约定关系是亟待解决的问题。关于人机交互界面,当前正向人机工程的方向发展,借助电子技术和信息技术成果,多媒介、多知觉(或全知觉)、全浸入的感知交互手段正在出现,涉及人的多类感官和头脑思维的信息化表示与协同动作,以及多人多媒介感知的协同工作。目前出现的采用虚拟顾问和虚拟战场实现人—机交互的高级共用作战图(HiCOP)<sup>[92-94]</sup>和采用具有符号、信息管理及协同功能,支持基于认知的用户精炼的可视化共用作战图(COP)<sup>[91,95]</sup>等人机界面正在向这一方向发展。

#### (6) 分布式评估挑战

信息融合评估主要是指对融合信息的效能进行评估,该评估与融合信息的应用效果紧密

联系。由于信息融合系统是为人提供感知信息的支撑平台,因此除了人参与和主导信息融合系统研制和应用管理外,人对融合系统的理解、运用以及人的经验、智慧和能力也与融合系统应用效能密切相关。故分布式评估问题是包括人在内的融合信息应用效能的评估问题,其与人在感知环中的挑战密切相关,包含多节点多人协同判断与决策的评估问题,当前,融合系统的评估研究以低级融合(0级和1级)居多,高级融合的评估研究进展缓慢,并且各国专家独立研究和应用产生的评估方法存在很大差异<sup>[42,43,97-101]</sup>。对于分布式评估挑战来说,除了为已采用的评估方法建立统一基准之外,亟待解决的问题是将评估从融合性能向应用效能扩展。向高端应用效能扩展是对融合信息在战略态势和发展路线中的应用效能进行评估研究,旨在为各国(以及全球)各领域发展路线提供及时、正确的系统信息支撑;向低端应用效能扩展在军事上莫过于对重要威胁目标的多平台协同打击效果的评估研究,旨在为确定对威胁目标实施连续打击或转移火力打击其他威胁目标提供实时、准确的依据。

## 参考文献

- [1] 赵宗贵,熊朝华. 信息融合概念、方法与应用. 北京:国防工业出版社,2012.11.
- [2] Kessler O. Functional description of the data fusion process. Report prepared for the Office of Naval Technology Data Fusion Development Strategy, Naval Air Development Center, Warminster, PA, November, 1991.
- [3] Hall D L, S A H McMullen. Mathematical Techniques in Multisensor Data Fusion. Norwood, MA: Artech House, 2004.
- [4] Hall D. Assessing the JDL model: A survey and analysis of decision and cognitive process models and comparison with the JDL model. Proceedings of the National Symposium on Sensor Data Fusion, Monterey, CA, 2006.
- [5] Dasarthy B V. Decision Fusion. Washington, DC: IEEE Computer Society, 1994.
- [6] Dasarthy B V. Sensor fusion potential exploitation-innovative architecture and illustrative application. IEEE proceedings, 1997, 85(1).
- [7] Steinberg A N, Bowman C L. Revisions to JDL data fusion model, chapter 2 of Handbook of Multisensor Data Fusion, Hall D L, Llinas J (Eds.). CRC Press, London, 2001.
- [8] Liggins M, D L. Hall, J Llinas. Handbook of Multisensor Data Fusion. 2nd. Boca Raton, FL: CRC Press, 2008.
- [9] Steinberg A N, C L Bowman, F E White. Revisions to the JDL models. Joint NATO/IRIS Conference Proceedings, Quebec City, Quebec, Canada October, 1998.
- [10] Hall M S, S A Hall, T Tate. Removing the HCI bottleneck: How the human computer interface (HCI) affects the performance of data fusion systems. Proceedings of the 2000 MSS National Symposium on Sensor and Data Fusion, San Diego, CA, June, 2000, 89-104.
- [11] Blasch E, S Plano. FIG Level 5 user refinement issues supporting situational assessment reasoning.

- Proceedings of SPIE, Wyndham, PA, 2002, vol. 4729, 270-279.
- [12] Kessler O, B Fabien. Estimation and ISR process integration. Report for the Defense Advanced Projects Research Agency(DARPA), Washington, DC, 2001.
- [13] Bedworth M, J O O'Brien. The omnibus model: A new model of data fusion? IEEE Aerospace and Electronic Systems Magazine, 2000, 15(4), 30-36.
- [14] Endsley M R, B Bolte, D G Jones. Designing for Situation Awareness: An Approach to User-Centered Design. New York: Taylor & Francis Group, Inc, 2003.
- [15] Endsley M R, L O Holder, B C Leibrecht, et al. Modeling and Measuring Situation Awareness in the Infantry Operational Environment. Alexandria, VA: U.S. Army Research Institute for the Behavioral and Social Sciences, Infantry Forces Research Unit, 2000.
- [16] Thomopoulos S C. Sensor integration and data fusion. Proceedings of SPIE 1189, Sensor Fusion II: Human and Machine Strategies, Philadelphia, PA, November, 1989, 178-191.
- [17] Pau L F. Sensor data fusion. Journal of Intelligent and Robotic Systems, 1988, 1, 103-116.
- [18] Harris C J, A. Bailey T J Dodd. Multi—sensor data fusion in defense and aerospace. Aeronautical Journal, 1998, 102 (1015), 229-244.
- [19] Carvalho R, W Heinzelman, A Murphy, et al. A general data fusion architecture. Proceedings of the Sixth International Conference on Information Fusion (Fusion 03), July 2003, Cairns, Queensland, Australia, pp. 1465-1472.
- [20] Lambert D A. Assessing situations. Proceedings of the IEEE 1999 Information, Decision and Control, Adelaide, South Australia, Australia, February, 1999, 503-508.
- [21] Lambert D A. Situations for situation awareness. Proceedings of the ISIF Fourth International Conference on Information Fusion, (FUSION 2001), Montreal, Quebec, Canada, August, 2001, 545-552.
- [22] Klein G A. Sources of Power: How People Make Decisions. Cambridge, MA: MIT Press, 1999.
- [23] Klein G A, C E Zsombok. Naturalistic Decision Making. Mahwah, NJ: Lawrence Erlbaum Associates, Inc, 1997.
- [24] Kaempf G L, G Klein, M L Thorsden, et al. Decision making in complex naval command-and-control environments. Human Factors, 1996. 38(2), 220-231.
- [25] Boyd J A. discourse on winning and losing. Technical Report, Maxwell AFB, Montgomery, AL, 1987.
- [26] Brehmer B. The dynamic OODA loop: Amalgamating Boyd's OODA loop and the cybernetic approach to command and control. Proceedings of the 10th International Command and Control Research Technology Symposium, McLean, VA, 2005.
- [27] Bryant D J. Rethinking OODA: Toward a modern cognitive framework of command decision making. Military Psychology, 2006. 18(3), 183.
- [28] Rousseau R, R Breton. The M-ODA: A model incorporating control functions and teamwork in the OODA loop. Proceedings of the 2004 Command and Control Research Technology Symposium, San Diego, CA, 2004, 15-17.

- [29] Grant T. Unifying planning and control using an OODA-based architecture. Proceedings of the 2005 Annual Research Conference of the South African Institute of Computer Scientists and Information Technologists on IT Research in Developing Countries, Mpumalanga, South Africa, 2005, 159-170.
- [30] Salerno J. Information fusion: A high-level architecture overview. Proceedings of the 5th International Conference on Information Fusion, Annapolis, MD, 2002, 1218-1230.
- [31] Salerno J, M. Hinman, D Boulware. Building a framework for situation awareness. Proceedings of the 7th International Conference on Information Fusion, Stockholm, Sweden, 2004, 680-686.
- [32] 赵宗贵, 许阳.信息融合动态与发展趋势.指挥信息系统与技术, 2014,12(6).
- [33] Waltz E, Llinas J. Multisensor Data Fusion. Norwood, MA: Arthch House, Inc, 1990.
- [34] Steinberg A N, Bowman C L, White Jr F E. Revision to JDL Data Fusion Model, Proceedings of the 3rd NATO/IRIS Conference, Quebec City, Canada, 1998.
- [35] Martin E Liggins, David L Hall, James Llinas. Handbook of Multisensor Data Fusion: Theory and Practice (Second Edition), CRC Press, Taylor & Francis Group, Boca Raton London, New York, 2008.
- [36] Steinberg A N, Bowman C L. Rethinking the JDL Data Fusion Levels. National Symposium on Sensor and Data Fusion, 2004.
- [37] Blasch E P. Ontological Issues in Higher Levels of Information Fusion: User Refinement of the Fusion Process. International Conference on Information Fusion, 2003.
- [38] Blasch E. P. Assembling a Distributed Fused Information-based Human-Computer Cognitive Decision Making Tool. IEEE Aerospace and Electronic Systems Magazine, May, 2000, Vol.15, No.5, 11-17.
- [39] Ballora M. Beyond visualization: Sonification. In Human-Centered Information Fusion, Hall. D. and J. Jordan (eds.), chapter 7. Norwood, MA: Artech House, Inc, 2010.
- [40] Harding N. 2010. Gartner: Data storage growth is the top challenge for IT organizations. Posting on IT Knowledge Exchange, November 3, 2010.
- [41] Chute C, A Manfrediz, S Minton, et al. The diverse and exploding digital universe: An updated forecast of worldwide information growth through 2011. IDC White paper sponsored by EMC, March, 2008.
- [42] Tapscott D. Grown Up Digital. New York: McGraw Hill, 2009.
- [43] Shirkey C. Cognitive Surplus: Creativity and Generosity in a Connected Age New York: The Penguin Group, 2010.
- [44] Palfrey J, U Gasser. Born Digital: Understanding the First Generation of Digital Natives. New York: Basic Books, 2008.
- [45] Albert D S, J J Garstka, R E Hayes, et al. Understanding Information Age Warfare. Washington, DC: CCRP Publication, 2001.
- [46] Department of Defence (DOD) USA, Joint Vision 2020. Hune, 2000.
- [47] CJCSI 3[5] 01A. Global Command and Control System Common Operational Picture Reporting Requirement. 19 January, 2003.
- [48] Chong C Y. Distribution Architecture for Data Fusion. In Proceedings of the 1st International Conference on

- Multisource Multi-Sensor Information Fusion, Las Vegas, NV, 1998.
- [49] Shong C Y, S Mori. Graphical Models for Nonlinear Distributed Estimation in Proceeding of the 7th International Conference on Information Fusion, Stockholm Sweden, 2004.
- [50] Hammond S C, M L Sanders. Dialogue as social self-organization: An introduction. *Emergence: Complexity and Organization*, 2002, 4(4): 7–24.
- [51] Wheatley M. *Leadership and the New Science: Learning about Organization from an Orderly Universe*. San Francisco, CA: Berrett-Koehler, 1992.
- [52] Cebrowski A K, J J Garstka. Network centric warfare: Its origins and future. *U.S. Naval Institute Proceedings*, January, 1998, 124(1): 35.
- [53] 雷德明, 严新平. 多目标智能优化算法及其应用. 北京: 科学出版社, 2008.
- [54] P K Varshney. *Distributed Detection and Data Fusion*. New York: Springer, 1997.
- [55] R Viswanathan, P K Varshney. Distributed detection with multiple sensors: Part I—Fundamentals, *Proceedings of the IEEE*, January, 1997, 85(1), 54–63.
- [56] R S Blum, S A Kassam, H V Poor. Distributed detection with multiple sensors: Part II—Advanced topics, *Proceedings of the IEEE*, January, 1997, 85(1), 64–79.
- [57] Reece S, S J Roberts. Robust, low-bandwidth, multi-vehicle mapping. *Proceedings of the Eighth International Conference on Information Fusion*, Philadelphia, PA, 2005.
- [58] Rogers A, A Farinelli, R Stranders, et al. Bounded approximate decentralized coordination via the max-sum algorithm. *Artificial Intelligence*, 2011, 175(2): 730–759.
- [59] Waldock A, D Nicholson. A framework for cooperative control applied to a distributed sensor network. *The Computer Journal*, 2011, 54(3): 471–481.
- [60] Dash R, A Rogers, S Reece, et al. Constrained bandwidth allocation in multi-sensor information fusion: A mechanism design approach. *Proceedings of the Eighth International Conference on Information Fusion*, Philadelphia, PA, 2005.
- [61] Rogers A, R Dash, N R Jennings, et al. Computational mechanism design for information fusion within sensor networks. *Proceedings of the Ninth International Conference on Information Fusion*, Florence, Italy, 2006.
- [62] Dash R K, D C Parkes, N R Jennings. Computational mechanism design: A call to arms. *IEEE Intelligent Systems*, 2003, 18(6): 40–47.
- [63] Reece S, A Rogers, S J Roberts, et al. A multi-dimensional trust model for heterogeneous contract observations. *Proceedings of 22nd AAAI Conference on Artificial Intelligence*, Vancouver, British Columbia, Canada, 2007, 128–135.
- [64] Reece S, A Rogers, S J Roberts. Rumours and reputation: Evaluating multi-dimensional trust within a decentralized reputation system. *Proceedings of Sixth International Joint Conference on Autonomous Agents and Multi-Agent Systems (AAMAS-07)*, Honolulu, HI, 2007, 1063–1070.
- [65] Walts E, Llinas J. *Multisensor Data Fusion Section 8.3*. Arthch House, Boston London, 1990.

- [66] Jehiel P, B Moldovanu. Efficient design with interdependent evaluations. *Econometrica*, 2001, 69(5): 1237–1259.
- [67] Zooniverse. Real Science Online. [www.zooniverse.org](http://www.zooniverse.org) (accessed on March 16, 2012.)
- [68] Erik Blash, Eloi Bosse, Dale A Lamber. High-level Information Fusion Management and System Design Chapter2. Arthch House, Boston London. 2012.
- [69] 陈伯江. 美国高级将领与著名学者访谈录. 世界知识出版社, 1998
- [70] Owens W A. The emerging system of systems. *U.S. Naval Institute Proceedings*, May, 1995, (121): 36–39.
- [71] Evidence Based Research, Inc. Network centric operations conceptual framework version 1.0. 2003. Report prepared for Office of Force Transformation, November, 2003.
- [72] Chang K C, Saha R, Bar-Shalom Y, et al. Performance evaluation of multisensor track-to-track fusion, in *Proceedings of the 1996 IEEE/RSJ International Conference on Multisensor Fusion and Integration for Intelligent System*. 1996, 627–631.
- [73] Chang K C, Tian Z, Saha R. Performance evaluation for track fusion with information fusion, in *Proceedings First International Conference on Multisource Multisensor Information Fusion'98*, Las Vegas, July, 1998, 648–654.
- [74] Chang K C. Evaluating hierarchical track fusion with information matrix filter, in *Proceedings of the Third International Society of Information Fusion*, Fusion, 00, Paris, France, 13 July, 2000, Vol. 1(10).
- [75] Chang K C, Mori S, Tian Z, et al. Map track fusion performance evaluation, in *Proceedings of the Fifth International Society of Information Fusion*, Annapolis, Vol. 1, July, 2002, 512–519.
- [76] David L Hall, Chee-Yee Chong, James Llinas, et al. *Distributed Data Fusion for Network-Centric Operations*. Chapter 2.
- [77] Chong C Y. Hierarchical estimation. *Proceedings of the MIT/ONR Workshop on C3*, Monterey, CA, 1979.
- [78] D Clark, S Julier, R Mahler, et al. Robust multi-object sensor fusion with unknown correlations. *Proceedings of the Conference on Sensor Signal Processing for Defence 2010 (SSPD2010)*, Imperial College, London, U.K., September 29 – 30, 2010.
- [79] M Uney, D Clark, S Julier. Information measures in distributed multitarget tracking. *Proceedings of the 14th International Conference on Information Fusion*, Chicago, IL, 2011, July 5 – 8.
- [80] M Uney, S Julier, D Clark, et al. Monte Carlo realisation of a distributed multi-object fusion algorithm. *Proceedings of the Conference on Sensor Signal Processing for Defence 2010 (SSPD2010)*, Imperial College, London, U.K., September, 2010, 29 – 30, 2010.
- [81] Lambert D A, Nowak C. The Mephisto Conceptual Framework, DSTO Technical Report DSTO-TR-2162, 2008.
- [82] Maupin P. Joussemme Interpreted Systems for Situation Analysis, *International Conference on Information Fusion*, 2007.
- [83] Blasch E, Salerno J, Kadar I, et al. Issues and Challenges in Situation Assessment (Level 2 Fusion), *December, 2006*, (2): 122-139.

- 
- [84] Blasch E, Linas J, Lambert D, et al. High level Information Fusion Developments, Issues, and Grand Challenges – Fusion10 Panel Discussion, Intl. Conf. on Info. Fusion, 2010.
  - [85] Lambert D A. TTCP C31 TP1 Annual Report. TTCP C31 Annual Meeting, Williamsburg, 2008.
  - [86] Allsopp D N. Coalition Agent Experiments: Multiagent Cooperation in International Coalitions. IEEE Intelligent Systems, May/June 2002, 26-35.
  - [87] Maupin P, A L Joussemme, H When, et al. A Situation Analysis Toolbox: Application to Coastal and Offshore Surveillance. International Conference on Information Fusion, 2010.
  - [88] Maupin P, A L Joussemme, H When, et al. A Situation Analysis Toolbox for Course of Action Evaluation. International Command and Control Research and Technology Symposium, 2011.
  - [89] U. S. Office of Management and Budget (OMB) Circular A -130.
  - [90] Blasch E. Sensor, User, Mission(SUM) Resource Management and Their Interaction with Level 2/3 Fusion. International Conference on Information Fusion, 2010.
  - [91] Blasch E, Kadal I, Salerno J J, et al. Issues and Challenges of Knowledge Representation and Reasoning Method in Situation Assessment (Level 2 Fusion). Proceedings of SPIE 6235, 2006.
  - [92] Lambert D A. A Blueprint for Higher-Level Fusion Systems. Journal of Information Fusion, 2009, Vol. 10, No.1, 6-24.
  - [93] Wark S, Lambert D A, M Nowina-Krowicki, et al. Situational Awareness: Beyond Dots on Maps to Virtually Anywhere. SimTecT, Adelaide AUS, 2009.
  - [94] Wark S, Lamber D A. Presenting The story Behind the Data: Enhancing Situational Awareness Using Multi-media Narrative. IEEE MILCOM, 2007.
  - [95] EricBlasch, Eloi Bosse, Dale A Lambert. High-level Information Fusion Management and Systems Design. ARTECH House, Boston/London, 2012.
  - [96] Valin P, Bosse E, Guitouni A, et al. Testbed for Distributed High-Level Information Fusion and Dynamic Resource Management. Proceedings of International Conference on Information Fusion, 2010.
  - [97] Blasch E, Plano S. Level 5: User Refinement to Aid the Fusion Process. Proceedings of SPIE, 2003, Vol. 5099.
  - [98] Blasch E. Situation Impact and User Refinement. Proceedings of the SPIE 5096, 2003.
  - [99] Blasch E. Proactive Decision Fusion for Site Security. International Conference on Information Fusion, 2005.
  - [100] Klein L A. Sensor and Data Fusion: A Tool for Information Assessment and Decision Making. SPIE Press, 2004.
  - [101] Theil A, Kester L J H M, Bosse T. On Measures of Performance to Assess Sensor Fusion Effectiveness. International Conference on Information Fusion, 2000.

# 第 2 章 面向网络中心战的分布式 信息融合

分布式信息融合与网络中心战的出现密不可分，它是应网络中心战（Network Centric Warfare, NCW）的战场感知需求而产生的，因此，网络中心战（NCW）的概念和内涵对分布式信息融合的概念和实现起着主导性作用。

## 2.1 网络中心战（NCW）的概念及背景

在信息网络支撑下的各种作战行动和作战样式的总和称为网络中心战。网络中心战不是指网络本身，而是体现网络起核心支撑作用的（也称由信息网络产生的）各种作战行为。网络中心战产生的背景是当前这场如火如荼的新军事变革。

### 2.1.1 新军事变革与联合作战

当前在世界范围内出现的这场新军事变革的目标是实现军队在装备上从机械化向信息化转型，在作战样式上从单军种作战向联合作战转变。因此在战场感知领域出现了许多新概念、新问题和新要求，其中分布式信息融合就是挑战性问题之一。

美国在 1977 年总结越南战场的惨痛教训时指出：“打了 14 年之久，死亡 58 000 余人，耗资 6 000 亿美元的越南战争，是美军沿袭二战传统战略的坟墓”<sup>[1]</sup>。因此，自越战结束后，美国便开始探索新的环境下新的军事战略和作战样式，其中的核心问题之一就是单一军种已无法主宰战场这一无法回避的现实。实际上在二战后期，美国将太平洋地区分成太平洋战区 and 西太平洋战区，分别由海军上将尼米兹和陆军上将麦克阿瑟指挥，导致总统无法协调陆军和海军的行动，出现了兵力分散，指挥不统一的情况，造成了较大伤亡。越南战争失败的主要原因之一是美地面部队与空军的协调问题。此外，1979 年营救伊朗扣押人质的失败，1983 年美入侵格林纳达以及什叶派炸毁美驻黎巴嫩陆战队营房，均由于缺乏各军种协同，造成了较大伤亡<sup>[2]</sup>。这些事实充分反映出单一军种作战已无法适应新的战场环境，从而成为这场新军事变革的动因之一。1986 年，美国政府出台了《哥德华特—尼科尔斯法案（Goldwater-Nichols ACT—GNA）》，即国防部改组法，旨在建立联合作战指挥体制，从而吹响了这场新军事变革的号角。其要点包括<sup>[3]</sup>：

- 减少指挥层次，提高指挥效率，只有国家指挥当局（总统和国防部长）和联合作战司令部拥有作战指挥权，各军种彻底退出作战指挥链，只承担联合作战保障任务；
- 参联会主席无决策权，但其建议通常会被国家指挥当局采纳，并且是联合作战的执



行者和监督者，由“弱势参联会主席”模式向强势模式转变，强化联合作战指挥体制；

- 大幅度加强联合司令部尤其是战区司令部司令的权力，实现扁平化指挥，强调联合战术行动、同步作战和协同作战；
- 完善联合作战计划机制，无论应对国家安全、局部冲突、反恐和维和行动，还是每年数百次大型军演，都预先制定周密、完善的联合作战计划和预案。

结论：单一军种已无法主宰多域战场，联合作战成为主要作战模式，即向多军种联合作战模式寻求作战能力的提升。

《哥德华特—尼科尔斯法案》为联合作战的作战模式奠定了基础，它是新军事变革的推动力，从而使实现联合作战成为这场新军事变革的主要内涵之一。

### 2.1.2 新军事变革与信息化

自 20 世纪 70 年代出现大规模和超大规模集成电路以来，以电子技术为主导的信息技术日新月异地进步，新的信息化武器装备不断涌现。随着精确制导弹药、远程打击武器、隐身平台、无人平台、天基平台、基于定向能的新概念武器等的出现，以及基于网络的各类指挥信息系统、情报预警系统、作战保障系统的出现和应用，传统的单一作战空间不断扩展。空海一体战、空地一体战、登岛作战和支地/支海作战以及远程和机动作战等作战样式均需要多军种参与，并且在各作战环节（OODA：观测、判断、决策、行动）上实现联合与协同。这充分体现了技术进步和生产力发展，特别是信息技术的发展对这场新军事变革的推动和主导性作用。美国前参联会副主席、海军上将威廉·欧文斯（A W Owens）精辟地表述了信息化与这场新军事变革的关系，他在一次采访谈话中说：“这是一场把人们的注意力从平台引开的革命，要改变那种认为作战能力是军舰、飞机、大炮的概念，…，我们关心的不是坦克甲板的厚度，而应把注意力集中放在思索信息和信息技术所能提供的作战能力上来”<sup>[4]</sup>。该谈话确定了军队从机械化向信息化转型的技术途径是向信息技术寻求作战能力的提升，或者说探索新的、基于信息技术的战斗力生成模式。欧文斯将信息化确定为军队转型的主要手段，从而使信息化成为这场新军事变革的又一重要内涵。

结论：探索新的基于信息和信息技术的战斗力生成模式——信息化将成为军队转型的主要技术途径。

### 2.1.3 新军事变革与网络中心战

由以上分析不难看出，联合作战是从这场新军事变革要实现的作战模式需求角度确定作战样式转型的目标；而信息化是从技术和生产力发展推动角度为这场新军事变革确定主要方法和手段，或称为作战能力生成模式转型目标。这两个目标的最终目的都是为打赢信息化条件下出现的冲突和战争（包括全球性反恐、反极端组织、基于地缘政治的局部战争等），或者说向信息化（包括信息化武器装备、信息化作战条令/条例、指挥信息系统和人）和联合作战（包括部队联合编成/结构、联合计划与联合行动）样式寻求作战能力的提升。

从历史唯物主义角度讲，技术进步推动生产力发展和军事变革，因此这场新军事变革的

两个主要目标和内涵并不独立而是紧密耦合,其中信息化是主导,其对联合作战模式的出现和实现起着不可替代的支撑作用。为此,威廉·欧文斯在1995年美国国防大学国家战略研究所发表的一篇文章中提出了这场新军事变革的技术模式是“多系统之大系统”(又称为系统集成, System of Systems)<sup>[5]</sup>,意指不同系统之间的相互作用会产生新的综合功能,是单一系统无法实现的。该大系统包含三类主要作战力量:战场感知力量、精确打击力量和决策指挥力量,这三类作战力量通过C<sup>4</sup>ISR系统集成到一起,如图2.1所示。

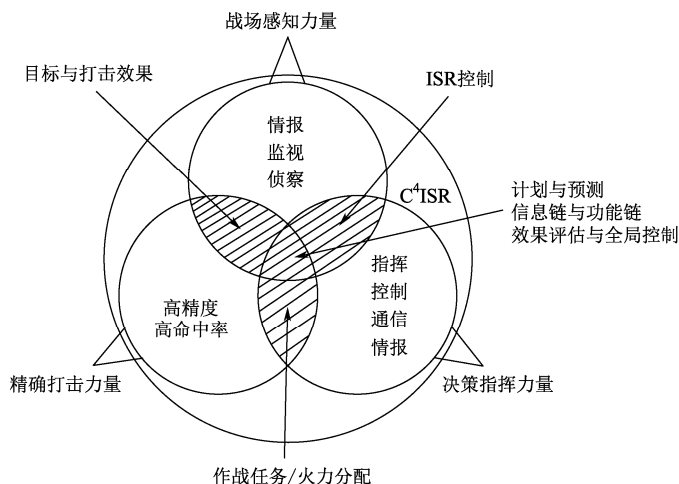


图2.1 新军事变革技术模式——系统集成

该系统集成的三大特征如下:

① 系统集成能产生整体大于部分之和的效果。从图2.1易见: C<sup>4</sup>ISR对指挥决策能力的提升能增强精确打击力量的效能, 战场感知实时提供的高精度目标会使火力打击更精确, C<sup>4</sup>ISR对战场感知力量的控制能获得全域战场信息优势;

② 该系统集成面向联合作战, 其中每种作战力量都是联合编成的, 并且在全域战场遂行作战活动, 称为联合作战力量。这将导致新军事变革最终产生新的作战力量编成模式, 即当前各单一军种编制模式将走向终结, 取而代之的是以相应作战环节全域作战力量的联合编成模式;

③ 三类作战力量的集成是通过信息网络实现的, C<sup>4</sup>ISR系统基于信息网络把指挥控制、战场感知和火力打击力量(平台和武器装备)无缝连接起来, 在整体上获得信息优势、决策优势和作战优势, 实现基于信息系统的体系作战, 最终达成最佳作战效果。

不难看出, 系统集成的上述三大特征实际上体现了信息网络的技术支撑和主导作用, 这也正是建立网络中心战(NCW)概念的基础。因此, 上述三大特征实际上使网络中心战成为这场新军事变革作战模式的主要内涵。网络中心战是1997年美国海军部长约翰逊上将相对平台中心战提出的, 将以海上平台为中心的局部作战能力扩展为以通信网络连接的多海上平台的大范围作战能力。美国国防部在2000年全球指挥控制系统(GCCS)中<sup>[6,7]</sup>统一采用了网络中心战(NCW)的概念, 因为网络中心战体现了这场新军事变革的技术模式与作战模式的有机结合, 成为当前多军种联合作战的实现模式。

结论: 基于信息网络生成的作战能力及其支撑的各种作战样式的总和称为网络中心战(NCW), 它集新军事变革作战模式与技术模式于一体, 成为信息时代当前的主要作战模式。

## 2.2 网络中心战（NCW）中的信息价值

### 2.2.1 网络中心战（NCW）中的信息价值概念

网络中心战（NCW）虽然在概念上以作战样式的形式出现，但其产生的各项作战功能具有强烈的信息依赖性。欧文斯的“多系统之大系统”及随后引伸出的网络中心概念和 NCW 军事概念的一系列出版物，都描述了基于信息的 NCW 体系作战中作战能力的逐级提升具体表现如下：

- ① 健壮的网络能大大改善信息感知和共享能力；
- ② 信息的融合与共享能提升信息质量并改善共享的态势感知质量；
- ③ 共享的、高质量的态势感知能提升同步作战和协同作战能力；
- ④ 及时、准确的态势感知能加快指挥控制节奏（缩短指挥周期）并增强持续作战能力和灵活应变能力；
- ⑤ NCW 形成的体系作战能力最终体现在显著提升任务效能、取得最佳整体作战效果上。

上述 5 点能力提升的核心是战斗力依赖于信息和信息技术，其中信息的可达性是信息共享程度的度量指标之一<sup>[8]</sup>，而正是网络（互联网），能够大大改善信息到达的经济性和信息创造价值的潜力。信息质量依赖于信息的真实性和可用性，其中可用性更加重要，因此真实的信息需要与应用紧密耦合才能够提升信息质量，产生信息效用。此外，高质量的态势感知还依赖于各共享节点之间的交互质量<sup>[9]</sup>，这涉及对态势信息的一致理解程度，直接影响信息创造应用价值的潜力。由此可见，战斗力与任务效能的提升依赖于信息共享、信息质量和各节点代理（人）之间的信息交互，而网络在其中起重要支撑作用。一个网络中的信息链条是：探测节点产生感知信息，其基于信息价值的预处理能够改善信息质量；探测信息传输给其他节点实现信息共享，这些节点可以基于任务目标进行融合或二次开发，改善信息质量；各应用节点通过网络交互达成对信息的一致理解，才能提高信息的可用性。总之，网络中的探测节点、融合节点和应用节点都能以相应的处理方式改善信息质量，从而存在一个可能的效能链，其影响系统集成产生的作战体系价值，也就是说，在 NCW 中存在一个基于效能结构的潜在“价值链”。

### 2.2.2 网络中心战（NCW）中的价值链

#### 1. 价值链的概念

“价值链”的商业概念是在产品开发过程中各阶段业务流程对产品性能产生的潜在影响的一个抽象<sup>[9, 10]</sup>概念，由于产品开发每个阶段都会增加该产品的价值并产生相应成本，因此价值链分析是多阶段产品全局规划的核心，是实现产品设计最优选择的基础，目标是达到产品价值最大和成本最低。当前，“价值链”术语已从商业界扩展到更广阔的范围。

在价值链讨论中，首先要假设各阶段的参与者（代理）具有全局观念和利他意图，以通

过同步交互、充分协作和无缝衔接达到产品价值最大化这个唯一目标（当然，成本最低有时也不得不考虑）；第二点是假设各合作代理之间的通信效率（信息可达性）对于网络的整体效能有着决定性作用<sup>[9]</sup>，因其直接涉及代理之间的信息交互质量。

网络中心战中战场感知价值链概念描述的是网络组织结构、信息流程（含信息流向与传输内容）、融合算法及生成有效情报产品等各环节的相互依赖性和对产品价值的贡献。其中网络设施处于中心位置，其对该价值链的核心支撑表现在两方面：①网络设施提供的框架将改进系统（含各单一节点）的信息质量；②该网络设施能提供增强的信息共享能力，进而产生更具想象力、灵活和及时的态势与威胁估计及作战决策。在 NCW 中，价值链必须满足每个代理具有献身和利他意图的假设，因为参战一方的各个网络节点都为一个共同的作战目标协同工作。此外，实现 NCW 价值链的期望目标还依赖于“战争迷雾”效应，即受到感知信息中存在的不确定性的影响以及具体任务风险或军事行动的紧迫性。由于局部或随机因素，即使是己方力量也不总是所有力量都能同步到一个方向上。此外，所实现的 NCW 潜能和预期的价值链流程还与作战意图紧密联系在一起，其牵涉到作战底层（包括部队、平台和信息系统）的开放性、协同性和预设的信息共享程度。这使得英国著名哲学家培根的名言：“知识就是力量”在这里可以具体化为“拥有和控制信息是产生力量的源泉”<sup>[11]</sup>。有些例子主张隐藏信息而不是共享信息是出于对信息使用的经济性和共享成本的考虑，这对建立优化的价值链流程极为不利。随着网络的出现和信息使用成本戏剧性的减少以及各类网络成本的显著降低，这一问题得到了有效解决。在一些新的应用案例中，各代理均参与增加价值的流程而不是有意削弱价值链。

美军在网络中心战中，通过构造“信息时代部队”和“联合特遣部队（JTF）”的方式变革战斗力生成模式，实现基于信息的联合作战，充分体现了信息对 NCW 价值链的贡献，即对作战效能的大幅提升。在该方式下，各种编成的作战部队（单一军种部队和联合编成 JTF）充分共享信息、协同遂行作战任务<sup>[11]</sup>。信息时代部队根据作战任务需要动态、灵活编成，并且通常对位于前沿的 JTF 指挥官授予更大的作战决策和自主行动的权限，即指挥权限前移，给前沿指挥官更大的权限，以灵活、自主地实现自组织和自同步作战。

## 2. NCW 价值链流程

从上一小节关于价值链基本概念的描述可知，在网络中心战中，战场感知信息的价值链条包含物理支撑层面的信息传输网络、信息获取和信息交互层面的信息共享、信息处理与融合层面的信息理解、作战指挥层面的最佳决策、战术活动层面的同步作战行动及最终的作战效能提升等 6 个环节，如图 2.2 所示<sup>[12]</sup>。

图 2.2 中，前 3 个环节处于战场感知领域，其价值体现在对感知信息质量的提升，后 3 个环节处于作战指挥与行动领域，其价值体现信息对作战能力（战斗力）提升的贡献。具体地说，传输优势产生于全速率、多节点、健壮安全的信息网络；信息优势产生于探测节点和融合节点生成的共享的、高质量的目标状态和属性估计及战场态势估计；知识优势产生于各节点对战场态势和威胁估计的一致理解；决策优势产生于指挥节点基于信息优势和知识优势的最佳作战方案和行动计划；行动优势产生于增强的同步作战和持续作战能力及高节奏作战

和应变能力；效能优势是指战役（战斗）行动最终获得的最优作战效果，体现任务效能的提升。不难看出，较好的网络是 NCW 的物理基础，而较好的效能是 NCW 的最终目标。在较好网络支撑下，通过 4 个中间价值链环节达成最终的效能价值，从而体现了这场新军事变革“系统集成”技术模式产生的“整体大于部分之和”的体系作战效能。

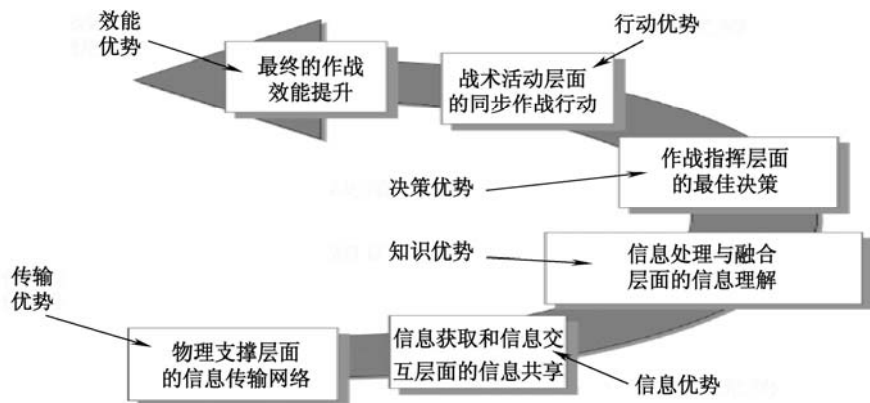


图 2.2 NCW 中的价值链环节

### 3. NCW 中的价值实现原理

为了确定 NCW 所产生的裨益，必须研究 NCW 各环节相关的价值链能够产生的效能，而该效能来源于对实际的作战节点的网络连接能力。众所周知，信息连接来源于多个层次的连接性，最底层是物理连接层（如电缆、光纤、发射/接收机），向上是通信协议层和消息格式层，在军事上还包含安全防护和信息的可达性控制等层次。为了在一个节点上融合多源信息，需要接收某些节点发送的信息，而这依赖于“信息共享策略(Information Sharing Strategies, ISS)”，其规定了发送节点和接收节点的对应关系以及采用的通信频段（手段）、传输协议和消息格式。ISS 是网络结构和信息结构的重要组成部分，在一个合作的多代理网络中，ISS 所涉及的各网络节点需要具有统一的关注目标和利他意图，才能有助于改善实际问题的求解，即使在作战紧迫和混乱不清的态势下也必须如此。

NCW 中的价值原理框架如图 2.3 所示<sup>[12]</sup>。

图 2.3 描述了网络能够增加的价值服务，它涉及网络连接的信息源、C<sup>2</sup> 功能节点、行动用户节点（作战单元/部队或平台）以及所体现的效用等因素。图 2.3 具体给出了 NCW 价值对战场感知网络和感知信息质量的依赖关系，通过有组织的信息质量和网络运行（信息传输）质量来支撑所增加的价值服务，并在共享信息传输与交互的意义下将二者结合起来。有组织的信息质量主要是指各网络节点基于预先组织的技术手段独自产生和控制的信息质量以及节点代理独自认知的信息质量。独自认知的信息质量包含节点代理（人）独自察觉、理解和判断产生的信息质量。网络运行质量涉及网络运行层次、所跨越的作战应用支撑层次及节点的网络连接状态，它们决定了信息的共享程度。共享程度包括信息的共享级别是察觉（目标）级，还是理解（识别或态势）级，或判断（指合作威胁判断）级，它们紧密依赖于多节点之间的信息交互质量，并与有组织的各节点独自的信息质量和认知质量相互补充、相互影响、融合提升。

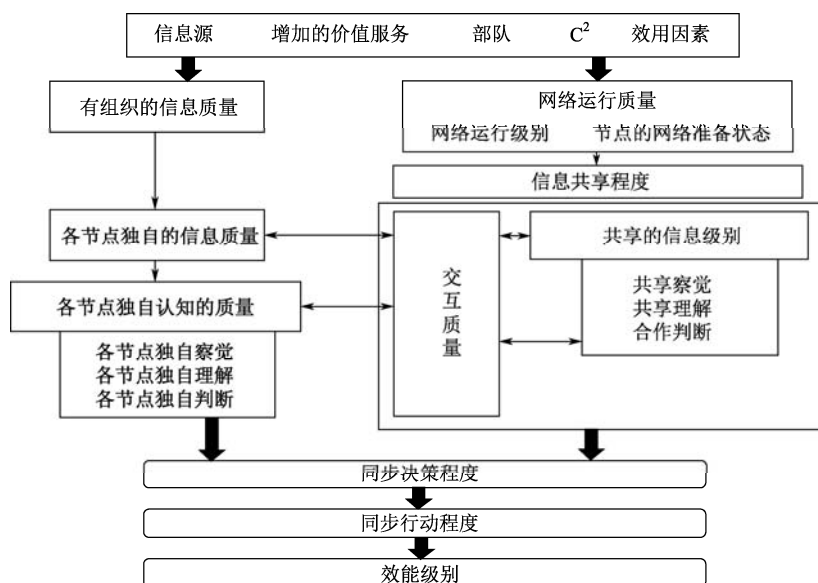


图 2.3 NCW 中的价值原理框架

图 2.3 底部描述网络及其连接的各节点的信息质量即该网络所提供的战场感知全局信息质量对各作战级别的支持程度，包括对指挥控制（ $C^2$ ）的同步决策支持程度、对作战单元（部队或平台）的同步作战行动的支持程度，以及所能够支持的作战级别（战术级、战役级、战略级）等。

值得指出的是，图 2.3 中出现的确定行为，如共享、交互、合作以及认知、理解、判断等都局限于战场感知范畴，可能跨越物理域、信息域、认知域和社会（这里指作战）域。每项行为的功能都旨在改善各节点的信息质量，这要求每个节点都要提供其独自获取的信息及质量，以通过网络（传输）交互加以改善，并最终出现跨越这些节点的网络级全局最优质量的感知信息。

### 2.2.3 最优行动的期望效用

一个节点的信息价值在应用意义上最终表现在一个节点代理（团队）或网络连接的多个节点代理使用该信息进行决策或行动所能够产生的应用价值（或效用）或带来的增益，可以采用相应决策和行动的输出结果的期望值进行度量。这种度量方法仅适用于常规的理性决策和行动问题，对于某些问题，如非对称问题，本方法并不适用，因为这类问题通常不产生理性决策和行动所期望的结果。

对于理性行为，假设在一个可能状态  $s \in S$ （ $S$  为所有可能状态的集合，或称为态势集合）之下，一个行动  $a$  的效用为  $U(a, s)$ ，则行动  $a$  基于所有可能状态的期望（平均）效用为

$$E\{U(a, S)\} = \sum_{s \in S} P(s)U(a, s) \quad (2.1)$$

式中， $P(s)$  为任一态势  $s$  的出现概率。由于  $s$  通常无法直接观测到，可采用间接获得的证据  $e$ （ $e$  可以从观测数据中提取或来源于含有所有可能证据的集合  $E$ ）来估计产生  $s$  的条件概率分布  $P(s|e)$ 。若极大效用  $U^*(a, S)$  依赖于所采取的最优行动  $a^*$ ，则

$$U^*(a, S) = U(a^*, S) = \max_{a \in A} \{E[U(a, S | e)]\} = \max_{a \in A} \sum_{s \in S} P(s | e) U(a, s) \quad (2.2)$$

对于任一  $e \in E$ ，最优行动  $a^*$  产生的极大效用的期望（平均）值为

$$\begin{aligned} E\left(\max_{a \in A} \{E[U(a, S | E)]\}\right) &= \sum_{e \in E} P(e) \max_{a \in A} \{E[U(a, S | e)]\} \\ &= \sum_{e \in E} P(e) \max_{a \in A} \sum_{s \in S} P(s | e) U(a, s) \end{aligned} \quad (2.3)$$

式中， $P(e)$  是证据  $e$  存在的概率。式（2.3）表示最优行动  $a^*$  产生的关于所有可能态势集合  $S$  和可能观测证据集合  $E$  的极大效用期望值（概率均值）。

需要说明的是：

① 如果集合  $E$  中各证据  $e$  相互独立，即各证据来源于相互独立的测量，如各证据（测量）由各独立探测传感器产生，且各证据源的关注区域 ROI 不相互覆盖，则式（2.2）和式（2.3）的极大效用期望可变换为离散求和形式，此时各  $P(s | e)$  是各状态  $s$  的边缘分布。

② 在各传感器关注区域相互覆盖，即具有共用测量信息重复计入的情况下，会产生各证据之间的相关性。此时， $P(s | e)$  是态势集合  $S$  中各状态元素的联合分布， $P(e)$  也是证据集合  $E$  中各元素的联合分布。这使得式（2.2）、式（2.3）中关于  $S$  和关于  $e$  的求和计算变得很困难。

③ 如果行动集合  $A$  中各元素相互依赖，则关于行动  $a$  的极大效用计算会呈现出巨大的复杂性。

④ 网络中心战的效用产生于多个环节所形成的信息质量，每个环节的信息质量依赖该环节采取的行动，并且各环节的信息质量相互依赖，形成一个如图 2.2 所示的 6 个环节构成的价值链。该价值链通常按序相互依存，即可视为一个动态马尔可夫过程，因此可采用动态规划或其他多阶段过程优化方法进行求解。

这里描述的最优行动  $a^*$  贯穿于图 2.2 所示的 NCW 中价值链的各个环节，为在各环节上获得相应的优势，各环节上都存在基于信息的决策和行动，如网络结构、最优传输路径、态势交互理解、作战方案和计划的动态生成、同步作战和协同作战行动及作战效能的综合评估等方面的决策和行动，这些决策和行动都需要基于信息价值或产生的效用进行优化。

## 2.3 网络中心战（NCW）中的认知问题

### 2.3.1 认知的概念

“认知（Sense—Making）”是一个过程，在一个信息网络中，认知是所期望的单一节点或网络能够达到的感知能力。对于一个人来说，认知过程主要指认识（Cognitive）人能够对某一认知级别（感受、察觉、理解和预测）的支持程度。对于具有认知能力的任一网络，无论是单一节点还是跨节点的子网络，其认知过程主要依赖于合作和信息交互模式。认知术语的几个推荐定义是：

- 认知是通过交互来感觉（Making Sense of）环境中的不确定性<sup>[13]</sup>的；
- 认知包含独立的、群组的、有组织的以及现实社会的认知活动，目的是形成关于对象

的感知和理解,并将理解与一个可行的行动空间关联起来<sup>[14]</sup>;

- 认知定义为在不确定情况下建立感知的过程<sup>[14]</sup>;
- 认知由认知域和社会域中一组活动或过程组成,其察觉有用信息始于信息域,结束于行动之前,意指建立相应域产生的任一单一效用或全域效用<sup>[15]</sup>。

上述定义的共同点是处理并阐明含有不确定性、异常和冲突现象的对象,建立该对象的一个现实估计视图<sup>[16]</sup>。通常,该认知框架包含6步构建过程:建立初始框架、改进、质疑、比较、再构建和框架维护。这6步是以迭代方式反复进行的,每一步都与人的思维模式有关,含有某种类型的决策和调节过程,以处理面对的复杂性、不确定性与模糊性。其中减少不确定性的努力可能不会立即产生效果,因为有的过程往往无法理解其中的不确定性和模糊性的含义而只能采用确定性方式建立。表2.1给出了人们无法准确知晓信息的几种典型形式(称为无知的形式)<sup>[17]</sup>。

表2.1 无知的形式

无知形式类别	定 义	校 正 措 施
不确定性	对于描述一个当前状态、预测状态、优选输出或达到这些所需要的行动等,缺乏充分的信息。不确定性可以用其程度度量(如用“概率”)来定义;然而,如果不确定性的关系(Context)含义是明确的,则对决策很有意义	减少不确定性需要有关该问题的关系(Context)的附加信息。通过将假设填充到缺失信息中或开发调整不确定性敏感区域的灵活响应,可以容忍不确定性
复杂性	面向变量、解法和需求方(Stakeholders)的相互关系集合的一个态势模式——每个因素各自领会,但合起来具有超出各独立元素、团队或组织的综合处理能力。所定义的复杂性与有用的经验和专业知识有关;对一个独立元素可能是复杂的,但借助其他元素可能易于理解	将问题向下分解为可管理的部件(分工)来调整复杂性。然而,这需要增加顶层管理以及相关专家一起将各类部件反向集成为一个完整的整体的方法
模糊性	不管有效信息如何,都没有能力清晰地感知一个态势。在面临不符合已有经验的新颖事物或态势时,会出现含糊性。这里所缺乏的不是信息,而是缺少正确构建和说明该信息的经验和专业知识,从而无法对该信息正确理解	模糊性可以通过获取新的知识源或者专家与需求方一起进行循环迭代合作来建立态势的新解释。当然,这需要建立充分的交互网络才能实现
多义性	对同一信息具有多个同等级别的似真说明。各说明可以在一个或多个维度上不同,包括说明判据、问题边界、特定低层因素关系、多个需求方(每一方对当前态势有各自的关注点)、预测的结论以及开展的响应行动等	多义性也可以通过专家与相关需求方一起进行循环迭代合作,讨论和协商予以解决。该过程可能会以民主或权威方式出现,其依赖于各相关方相互影响或是否可能存在一总体决策权限

认知过程并不受通常的理性判定假设和模型的限制,也不受人们所归纳出的极大化决策效用函数所约束<sup>[18]</sup>。因此,认知过程很可能面对许多违背常理和准则的“不合理”的行动,例如:非对称策略和行动、恐怖主义行动以及战场上的伪装、隐蔽和欺骗行为。此时,决策者必须采用不按常规出牌的相应“不合理”策略来应对。为了能够准确认知“不合理”行动,可以考虑采取多代理合作网络群组的态势估计方式,将各代理对包含不可知、动态现实及涉及欺骗、模糊信息的部分认知结果进行综合,构建一幅主观态势视图。在这个过程中,有界的理性模型对各代理的认知及认知综合会有帮助。当然,所采用的有界理性模型与网络群组认知并不是一回事,网络群组认知在概念上是指构建某复杂现实的一个充分说明,以达到所承诺的认知状态,并导出相应决策和行动状态。该概念与自组织群组认知过程也有区别,自组织群组认知是对群组设置的目标和认知对象采取的行动与搜集的信息进行逻辑性预测。实



际上，自组织的概念是指动态设置群组自身目标和对象。在作战活动中，传统军队显然无法适应需要进行模糊、不确定性认知的作战任务，因此，指挥官应尽量减少对所属部队群体发布模糊任务，而不是只规定模糊的基准边界。在信息融合领域，大多数传统融合操作是对所谓的显式信息（即含有一定偏差的不确定性信息）进行的，而对于内涵无知，包括动态变化无知和意图、能力等知识无知的隐式信息，则显得无能为力，这也正是 NCW 分布式信息融合的挑战性问题之一。

表 2.2 对认知的内涵和面对的问题进行了深化与扩展描述<sup>[18]</sup>，这些问题都属于分析和决策中具有不同困惑程度的问题，其求解在很大程度上需要改变人们内心的原始想法并摆脱历史的偏见<sup>[19]</sup>。

表 2.2 认知问题的分类与特征

分 类	特 征
问题状况	<ul style="list-style-type: none"> <li>从已知确定性问题转变为未知恶劣问题（含分歧、冲突信息）；</li> <li>无法基于功能专家和应用方的总体和方向性的指导意见，为当前态势建立一个清晰、一致的目标族；</li> <li>时间和其他资源约束要在目标和作战需求中折中选择</li> </ul>
信息状况	<ul style="list-style-type: none"> <li>可用信息量和信息可靠性不足，难以形成有效收集、说明和组织信息的能力；</li> <li>不同功能专家和应用方基于其视角和专业知识的对可用信息存在多义、冲突理解；</li> <li>作战态势所显露出的决策在特征、关系和要求上可能出现不一致的模式；</li> <li>功能专家和应用方勾画其视图所采用的符号和意会无法使其他人一致理解</li> </ul>
决策和应用状况	<ul style="list-style-type: none"> <li>功能专家和应用方所依据的潜在价值、政治目的或情绪反应可能不同；</li> <li>各有关参与者缺乏一个清晰、一致的角色与响应能力分配方案；</li> <li>决策者缺乏作战评估和未来决策与行动的一个清晰、一致的效用度量系统；</li> <li>关键决策者、功能专家和应用方要随着演变的作战态势而改变</li> </ul>

### 2.3.2 认知的本质和过程

认知也被称为“构建现实”，它是一个以行动为中心的可回溯过程。类似于融合学界所谓的“激励智能”，即采取行动来激励一个对手进行观测或“辅助其理解”一个假设的行动。这种策略通常在物理级别上很成功，如设法产生操控物理对象的行动，例如对传感器的探测控制。在信息和认知级别上难以定义和执行这样的策略，或很少取得成功，其主要原因是难以进行操控和观察。认知过程往往是偶发和自适应的，为易于控制和处理，需要将其保持在一个线性的推理框架中。由于问题求解者不情愿简化说明和采用不符合其指定假设的信息，于是可采用一个弹性的承诺来表征。随着过程的不断适应，还可能意识到来自知识管理功能需求的更多的认知特征，通过管理使动态目标轨迹符合指定线性假设和相关知识模型，从而防止收敛过程出现反复和失败。图 2.4 是以预设的常规基于作战节奏的线式决策过程与实时作战过程中出现的突发决策过程的混合形式表示的认知过程，两类过程在基于任务周期/作战节奏的短暂关系中合作运行<sup>[20]</sup>。如图 2.4 所示的作战过程，一个作战周期的各作战节奏是：第一个节奏为态势生成和理解过程，生成战场态势图；第二节奏是作战方案/计划生成过程，产生作战计划图；第三节奏是作战行动组织过程，生成协同行动图；第四节奏是作战评估过程，产生打击效果图。其中每个节奏都是线式过程与突发过

程的混合，即动态合作模式。

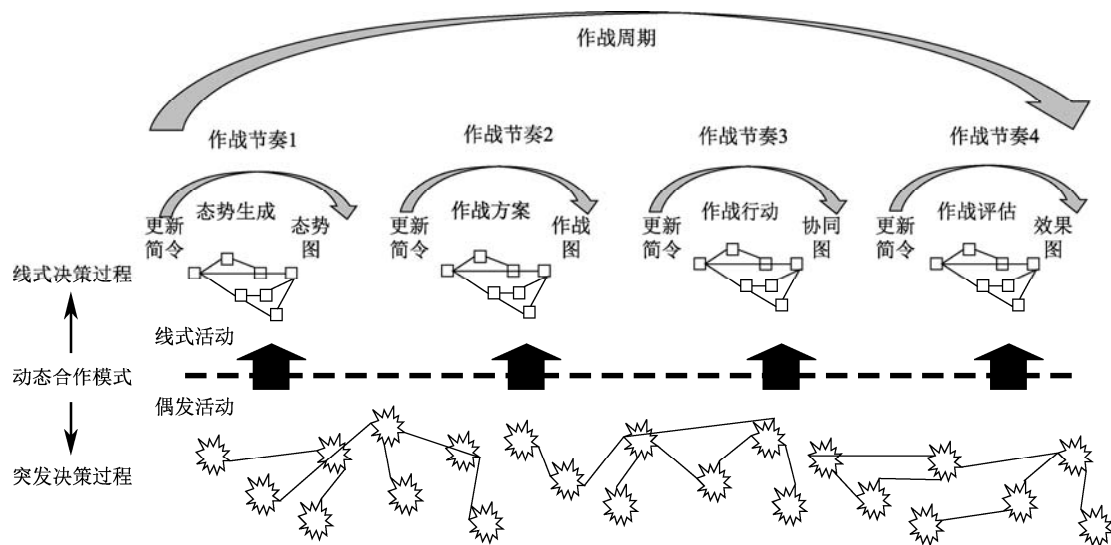


图 2.4 NCW 认知过程的动态合作模式

图 2.4 所示的动态合作认知过程所包含的功能部件的内涵及其在认知过程中的作用如表 2.3 所示<sup>[21]</sup>。

表 2.3 认知过程的表征

认知过程部件	该过程部件做什么	该部件在认知过程中的作用
布势讨论 (基于信任)	<ul style="list-style-type: none"> <li>团队中各类功能专家和应用方提出他们的布势(视图),尽量形成结构化问题框架;</li> <li>合作过程:每方都力图改变或扩展其他方的知识状态,以寻求对每个相关元素的共同理解,并将可能求解途径凝聚成一个整体;</li> <li>合作过程中存在争议</li> </ul>	<ul style="list-style-type: none"> <li>解决面临的恶劣(分歧、冲突)问题挑战,构建一个适宜的认知问题框架,以形成最终的合成决策;</li> <li>恶劣问题通常包含每个专家或应用方对相关威胁和机遇的不同看法,这是由于他们的任务和专业知识不同所致</li> </ul>
似真的期望 (基于信任)	<ul style="list-style-type: none"> <li>主要领导者表述对确定输出、事件和未来状态的期望,以凝聚其支持团队成员的关注点和想法;</li> <li>期望与对行动的信任相联系,即隐式构建的未来需要确定的行动或必须由团队、组织规划和执行才能达成;</li> <li>期望投射出所构建的未来,随时间演进,以符合展现出来的事件和状态</li> </ul>	<ul style="list-style-type: none"> <li>一个团队或组织的认知效率依赖于其领导者对其成员的关注点和想法的聚焦能力;</li> <li>一个领导者的职责是为团队和组织构建所缺失的可能未来景象;</li> <li>把设想、团队和达到的目标连接起来是形成不同决策行为的强大推动机制</li> </ul>
行为承诺 (依赖于行动)	<ul style="list-style-type: none"> <li>主要领导者要明确、公开、不可改变地展示其对具体计划和行动的承诺,以进一步形成并聚集其支持团队和组织成员的关注点和想法;</li> <li>该承诺以批准计划和下达命令的形式发布;</li> <li>该承诺用达到的目标、行动次序和付出代价的形式提供给团队或组织</li> </ul>	<ul style="list-style-type: none"> <li>个人、团队和组织围绕其所承诺的行动尽力严格构建含义并理解;</li> <li>在领导展示承诺之前,该团队或组织的各类察觉、经验和布势与不断变化的态势仅是松散的耦合;</li> <li>领导的承诺将无组织的察觉、经验和布势变换为更有秩序和目标的群组</li> </ul>
环境操控 (依赖于行动)	<ul style="list-style-type: none"> <li>团队和组织在其作战环境中有选择地行动,以使其构建的现实与环境达到一致;</li> <li>操控反映团队或组织在主动塑造未来中的作用;</li> <li>操控可以采用预先缺省行动的方式,甚至在问题空间完全理解之前塑造该问题空间</li> </ul>	<ul style="list-style-type: none"> <li>认知不仅是被动解释运行环境,还包括主动构建团队或组织作战中可能出现的现实;</li> <li>认知把信任和行动在一个可理解的框架中连接到一起,因此,构建一个现实包含构建的假设和采取的行动</li> </ul>

表 2.3 中, 布势讨论主要指一个利益共同体 (Community Of Interest, COI) 中各专家一起增进对问题和指定行动的共同理解, 这有助于确定当前假设或辅助该推理过程。对决策行动似真期望主要由团队主要领导者以规划结论或事件的形式建立。行为承诺依赖于行动, 在某种意义上说, 承诺是一种方法, 能够将认知过程聚焦在问题空间中的具体因素上, 这些因素反映领导者的意图, 并能够落实到采用的行动方案中。环境操控主要针对行动, 目的是辅助开发该“构建的现实”, 以形成该团队的解释框架。

## 2.4 网络中心战 (NCW) 中的自组织和自同步

### 2.4.1 网络中心战 (NCW) 的主要特征

与传统基于消耗对抗战略的作战样式相比, 网络中心战具有下述特征:

① 典型的分布特征。NCW 中每个局部范围里的节点都由感知功能和作战功能耦合产生, 与 OODA 各环节相对应; 全局功能则体现在各局部节点和各环节功能的协调上。于是, 传统集中优势兵力的作战原则成为历史, 而不同地点、不同时间、不同行动、同时到达的协同作战成为主要的作战原则。

② 显著的信息化特征。NCW 属于信息时代的作战样式, 是这场新军事变革产生的具有显著信息化特征的初始作战样式。其基于计算机网络、信息化武器装备和指挥信息系统实现作战能力的大幅提升, 并产生联合/协同作战的多种形式, 以应对面临的诸多威胁。

③ 全谱作战。NCW 的全谱特征使其大大超出了传统军事作战的范畴, 其中, 军事对抗、地缘政治冲突、民族宗教矛盾、国家权益维护、资源争夺、贸易战与金融危机及阶级斗争等多领域因素交织在一起, 极其错综纷乱, 从而产生许多前所未有的新的全谱作战样式。

④ 全域作战。NCW 将作战区域从单一空间扩展到多域甚至是全域空间, 各军种和联合部队的作战行动可能跨越陆、海、空、天、Cyber 和电磁频谱等各领域。

⑤ 非对称性。NCW 往往面对非对称作战样式, 双方均采用以己之长制敌之短的策略, 以取得期望的作战效果。

⑥ 非理性。NCW 中会出现无法按理性行为合理预测的作战样式、行为和效果, 在非理性行为的识别中, 人的认知能力起主导作用, 对非理性行为需采用非对称的非理性行动来应对。

⑦ 非线性。指不按传统作战基线 (时间基线、空间基线和任务基线) 和预设作战阶段遂行作战活动的过程, 非线性作战已无传统战争的一、二、三线概念, 甚至已无战术和战略的区别且无法划分作战阶段, 如斩首行动, 察打一体等。

⑧ 突发性和随机性。NCW 面对的事件和样式在时间和空间上具有突发性和随机性, 这给对恐怖分子和极端组织的防范带来了极大困难。

⑨ 高节奏和并行作战。战场态势的快速变化以及战场事件和行为的突发性使按阶段、时节的传统线式作战节奏走向终结, 取而代之的是以高节奏和多阶段/多时节的并行

作战样式,甚至在战争开始就寻求战争的结束。

⑩ 自组织和自同步作战。在 NCW 中,传统按作战任务预先编成、按计划组织兵力和行动的模式和自上而下的按时限组织指挥体制正走向终结;取而代之的是以一个作战单元/群组的自组织和自同步作战,具体见下文的描述。

### 2.4.2 自组织的概念和效用

自组织的概念来源于一个团体或群组为达成一个目标所进行的认知和行动过程。在 NCW 中,一个作战单元的自组织来源于其在遂行一项作战任务中自主进行的战场感知和作战活动,其中各成员对认知和行动的扩展、差异、不理解和不确定等概念的含义可能具有不同的认识。其中,认知扩展的自组织涉及相互交流,以产生新的社会动态认识,如通过对话产生新的认识就是一个自组织过程<sup>[22]</sup>。通过交流能够在随机产生的无序和共享产生的有序之间在含义上进行扩展,以产生一个一致理解的含义和次序。然而,认知的差异即多义性(不同理解)会在交流过程中产生新的无序现象。例如,在汇集团队各成员的想法产生的意见扩展中,会出现一些新的意见,这是处于混乱或模糊环境中的各成员的认知存在对同一问题的歧义理解所致,从而对汇集产生一个一致的意见产生负面影响,或产生局部“混乱(Chaos)”<sup>[23]</sup>,这会导致放弃合理意见而寻求预定范围之外的解决办法,最终无法达到预定目标。然而,通过自组织会使负面影响和局部混乱达到最低,并从中产生有序和一致的、预定范围之外的更高明的解决办法,更快达到预定目标。由此可见一个团队对其认知和行动的自组织是达成预定目标的必要条件,在 NCW 环境中,一个作战目标(一次作战任务)往往涉及多个作战单元(作战平台),自组织通常要针对多个作战单元的整体认知和交织在一起的作战活动进行,因此具有更高的复杂性。

由以上分析不难得知,自组织的通用概念是一个团体或群组为达成一个共同目标所进行的自主认知和行动的组织过程。与自顶向下的组织指挥与行动方式不同,在 NCW 环境中,自组织是指在没有或缺少主导者(上级)的情况下,对达成一个作战目标(一次作战任务)的多个作战单元(作战平台)自下而上或在同一级别上进行的整体自主认知和交织在一起的作战活动进行自主组织和实现的过程。其中,整体认知既包含对战场态势的全局感知,又包含对作战决心、方案和计划的一致生成和理解;交织在一起的作战活动既反映多域战场在时空上的交织,又反映多军兵种作战力量的协同运用,从而展现了 NCW 环境中自组织的高度复杂性。

### 2.4.3 自同步的概念和效用

自同步的概念来源于网络中心战,最早是由 Cebrowski 和 Garstka 提出的<sup>[24]</sup>:“自同步是一种作战力量编成自下而上组织并同时遂行作战活动的能力。组织原则是作战力量、指挥员意图、作战规则的统一。自同步只有通过对自己方力量、敌方力量及所有适宜的战场态势要素(知识)的深层次理解才能实现。自同步能够克服许多常规条例中具有定向同步特征的自顶向下指挥方式和从一步功能转变为高速连续作战所固有的战斗力损耗。”其中一步功能是指

按步骤（阶段或时节）逐一行动的串行作战方式，高速连续作战通常是指高节奏作战和多步骤并行的作战方式。自同步的简单定义是<sup>[25]</sup>：“一个编成力量自底向上组织和协调复杂作战的能力”。

“自同步”概念中的“自”通常是指在没有其他代理的影响和控制时，一个代理对自身活动的时间分配能力，是该代理独立进行的一种安排。在对抗活动中，一方代理通过独立的分析和判定来安排活动时间，通常需要采取预先行动，否则只能被动地局限于对手驱动的反应之中。实现自同步所需要的其他元素还包含在所有时间维持指挥员关注的感知，即按意图获取信息，以对作战活动动态优先排序。严格说来，这并不是一个代理独自进行的，现实 NCW 中的“自”的概念与一类集群自同步有关，该集群中的每个代理需要协同思维并具有共享资源和能力的愿望。这也意味着存在一个代理作为合作的通信发起者——同样也能够接收并理解其他合作者意愿，这样才能够达成对双方代理都有帮助的行动，而不是从协商的交流行动产生折中的结论。最后一点，自同步集群（作战单元）本身要按照所承担的任务和作战样式进行编成，其形成的作战能力蕴含在人、任务和资源所形成的一种关系之中。自同步的这些因素与“高效能人士必不可少的七个习惯”类似<sup>[26]</sup>，其定义的强制性规定包含事先预测、按意愿（指挥员意图）操控、优先排序、协同思考以及首先寻求理解等。

由以上概念的讨论和分析可以看出，与按预先设定的时限同步作战方式不同，更与传统自顶向下指挥控制方式不同，NCW 环境中的自同步是指一个智能（具有知识）作战单元自下而上或在同一作战级别上，随战场态势的变化，迅速组织兵力、确定和调度作战任务、设置行动时限，以实现快速反应作战的能力，其中的“自”是指该作战单元独立进行的作战活动时限安排。在多个作战单元构成的作战集群中，自同步中的“自”与该集群中多作战单元的同步作战活动有关，此时将该集群视为各单元协同思维、共享资源、具有同一目标的一个统一体。

## 2.5 分布式信息融合在网络中心战（NCW）中的作用

### 2.5.1 分布式网络中心战（NCW）与分布式信息融合

由于新军事变革的技术模式——系统集成只有通过信息网络才能实现，而系统集成旨在为实现联合作战提供技术支撑，因此以网络为核心的 NCW 将新军事变革的作战模式和技术模式紧密耦合在一起。我们注意到，当前在世界范围内出现的基于地缘政治和资源争夺的局部冲突、全球性反恐和反极端组织等局部作战行动中，信息化战争的作战样式已初步成形。1991 年的海湾战争是这场新军事变革效果一定程度的展现，使人们看到了“代差”（即信息时代与机械时代作战能力的差距）成为联军致胜的主要原因<sup>[27]</sup>。美军在总结自 1990 年后出现的历次局部战争的经验和教训时，提出了诸如非对称作战、非线性作战、非接触作战、防区外发射、精确打击、网络战与电子战、斩首行动和先发制人行动等作战样式，尽管尚不成熟，但已带有明显的信息时代特征。其中一个显著特征是：作战力量不能集中而只能分散部署，通过网络将其连接起来，实现各作战力量的联合或协同作战行动，如火力集中或协同打击行动，这就是网络中心战概念出现的动因。作战力量分散部署和协同作战行动表明 NCW

在本质上是分布式的。

我们知道,信息融合学科是基于环境感知领域应用产生和发展的一个边缘学科,其效能与相关的应用效果紧密联系。军事领域的信息融合是战场感知的主要环节,它必须与作战应用紧密结合在一起。值得指出的是,在军事领域强调战场感知信息只为情报服务,即强调情报是单一独立战线的观点在信息时代已走向终结。如前文所述,信息时代的网络增强了信息和机遇的实时性,加快了作战节奏。因此,只有将实时感知的战场信息直接为实时的作战指挥控制和火力打击服务,才能发挥出其最大效能。这样分布式的 NCW 必然导致分布式信息融合功能与作战功能紧密耦合在一起。也就是说,在 NCW 中,自下而上的集中式情报保障成为历史,而分布式全向信息服务成为现实需求;单一独立的情报战线体制走向终结,与各级作战活动紧密耦合的实时情报保障体制已经开启。图 2.5 描述了与作战指挥(决策)节点紧密耦合的三层分布式信息融合结构。

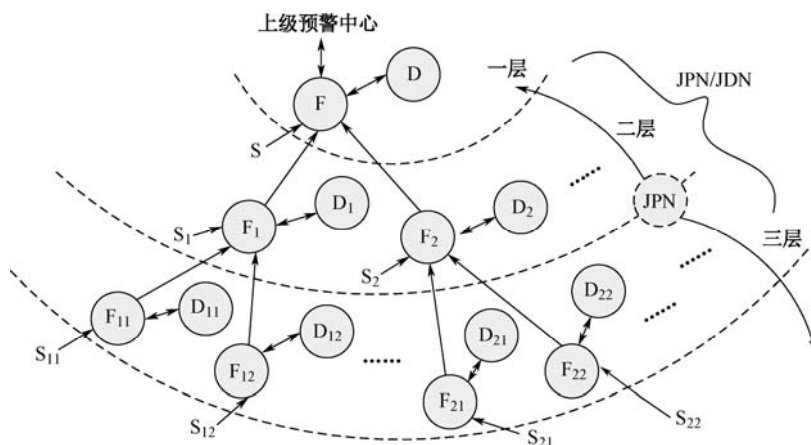


图 2.5 与作战指挥节点紧密耦合的三层分布式信息融合结构

图 2.5 中,信息融合节点(以 F 开头的)面向两种功能线,一种是情报预警线(以 S 开头的):态势感知信息逐级上报,为战场预警和高级(战略或战役)作战决策服务;另一种是作战指挥线:态势感知信息直接为本层作战节点或通过网络为其他作战节点服务,包括威胁判断、作战决策、指挥控制或火力打击,基于具体需求确定。当然,不同作战环节的情报信息需求在精度和实时性上也不相同。图 2.5 所示的三层网络中,第一层节点表示国家联合指挥中心(NJCC),属于战略级;第二层表示战区联合(军种)作战指挥中心(TJCC 或 SCCC),属于战区/战役级;第三层表示部队指挥所/火力控制点(PFC/FCS),属于战术行动级<sup>[28]</sup>。美军在这个三层分布式结构中采用的连接网络分别是联合计划网络(JPN,第一层及其与第二层的互联)、联合数据网络/数据链(JDN/DIL,第二层及其与第三层的互联)和数据分发系统(DDS,用于战术单元/平台火控数据互联)。

### 2.5.2 信息融合对网络中心战(NCW)价值链的贡献

信息网络中的任何融合节点仅能融合两类信息,其中一类是预先有组织地从探测节点或信息源控制接入的信息;第二类是网络中基于设置的信息共享策略(ISS)从其他节点(信

息处理和融合节点、外部信息接入节点)到达的信息,通常具有随机性和不可控性。第二类非组织信息可能是相互交织的 ISS 多样性产生的信息流的综合结果,如来自某些节点的传播、响应其他节点的信息服务请求和来自接收节点的订阅信息流,以及采用某些专用协议驱动的其他信息流模式等。一个节点的“非组织”融合状态是各种已定义的协议和策略产生的结果,或对响应直接请求信息流的综合结果。

由此可见,信息融合节点能够成为系统设计实现的信息质量、人的认知和理解的信息质量的重要贡献者,无论对于独立的用户或入网节点用户以及多点共享用户皆是如此。众所周知,JDL 信息融合顶层模型中的“第 4 级:过程精炼”功能,能够通过各融合节点之间的交互,特别是各融合级别(从低级的信号融合和对象融合到高级的态势估计与威胁估计)节点之间的逐级交互,获得全局信息质量的提升。当然,节点之间的交互依赖于网络管理和信息流控制权限,网络结构和带宽是信息融合质量的重要依赖因素。

任何融合系统的设计必须面对系统的两种需求方式,即“推动”——由输入端数据驱动系统运行,以及“牵引”——由用户端模型驱动系统运行。网络环境可能以多种方式影响这两种需求方式,如网络中的信息流会产生滞后(延误)、非时序到达或到达率可能服从泊松分布(同时只能到达一个信息),这些都潜在地影响融合系统的效能。网络中各融合节点通过设置(预先建立)用户需求模型,寻找符合用户需求的输入数据并向其赋予涵义;或者对序贯接收的输入数据进行时序划分,挖掘其中含有的统计规律和专业应用知识;也可以采用人机交互方式兼容这两种需求样式,实现多源输入信息的融合,提升信息质量。与此同时,网络中各融合节点针对网络的弊端,能够通过网络带宽的合理分配、传感器节点的协同控制、自利用户节点的理性合作以及选择适宜的优化融合算法来克服网络资源约束产生的负面影响,全面提升系统输出的全局感知信息质量。

融合节点对网络信息质量的提升充分体现了融合功能在信息网络中的价值。

### 2.5.3 信息融合在网络中心战(NCW)认知中的作用

认知需要基于计算机对感知信息进行融合处理,这需要对感知所涉及的各类信息和知识具有一定程度的理解,信息与知识源通常包括基于经验归纳和整理的信息与知识、默认(公认)的知识和社交知识<sup>[20]</sup>。显然,来自一个信息融合输出过程的知识属于整理知识领域,融合数据的信息源也大多归入整理信息领域。认知所依靠的一类重要信息源是关系(Context),即关系是认知的源泉之一,或者说认知是对现实关系的理解和说明。Context 是针对未定的问题、不透明的答案或需要商定的协议所构建的,目的是减少混乱<sup>[29]</sup>。因此,Context 是一个具有多种解释(即针对不同的问题和环境具有不同的解释)的圆滑词汇,很难与“态势”区分开,因为态势也是随战场状况和环境的变化而不断变化和演进的,其内涵也具有强烈的状态依赖性。通过 Context 与态势相互作用实现对战场的全面、准确、动态认知是信息融合对认知的主要贡献。其中周边关系(Contextual)信息在对具体的 Context(或态势)融合认知中起举足轻重的作用,其具有两个角色:①先验角色,预先主动设计融合算法时,要预先确定与该融合算法有关的周边关系信息,并将其集成到算法设计中,如利用地形信息跟踪地

面时敏目标就是一个例子；②后验角色，凭借周边关系信息进一步理解和约束独立开发的融合结果，即在产生融合推断结论之后，周边关系信息用来对其进行改善。这需要设计一个用于选择、修正和使用适宜周边关系信息的“滤波器”，以使周边关系更清晰。在认知过程中，周边关系信息的使用是相对静态的，也可能是动态的（如天气），这会增加一层复杂性，并且使认知过程易受各种偏差效应影响。

认知过程需要一类非单一逻辑支持，当缺少可靠的因果模型时就会产生一个条件（原因）下的多个或未知的结果，因此溯因（该模型）过程模型很有吸引力，它用于从一个结论向多个（或未知）可能结论的扩展，其采用似真度而不是精度表示各结论的可能性<sup>[30]</sup>。当条件因素存在不确定性或仅局限于“征兆”消息时，也必然会出现外展过程（产生多个可能结论）。显然，外展过程可以采用传统推演（deductive）的数据融合框架来驱动，只是此时采用的不是单一推理（即产生单一结论）过程，信息融合中将其称为不确定性综合或基于不确定性的推理过程，如基于概率的贝叶斯推理、基于基本概率赋值（可信度）的D-S证据推理、基于隶属度的模糊推理等。变权综合也可以视为非单一推理过程，尽管只产生唯一结论，但该结论随权重的变化动态改变。

信息融合对认知过程的支撑及发展状况如下：

- 信息融合过程能够支持当前出现的认知决策过程和理性行为决策过程，或二者共存的决策过程，基于不同问题分类所需要的这三类决策过程需要不同的数据融合过程提供支撑；
- 信息融合学界目前正在对传统信息融合过程进行扩展，以提升对认知过程的支持力度。这个扩展随认知过程，特别是随对无知类型的深化认识而没有止境，即所谓“魔高一尺，道高一丈”；
- 信息融合学界正在探索和开发新的融合模型，以支持新的认知过程，包括探索新的融合功能以及建立该功能模型可能遇到的技术挑战。

## 2.5.4 信息融合在网络中心战（NCW）指挥控制中的作用

### 1. 指挥控制（ $C^2$ ）的复杂性

网络中心战的指挥控制（ $C^2$ ）面对的是一个动态的不对称战场，因此 $C^2$ 必然存在面向各种不对称态势的多种可达状态，并且 $C^2$ 各状态之间的变化必须与NCW自身的变化相匹配。来自文献[31]的这个“需求变化准则”意味着 $C^2$ 系统必须表现出极大的灵活性以处理混合编成的联合任务部队（JTF）作战的动态性和复杂性。因此，网络中心战中基于人的 $C^2$ 的控制功能极其复杂，这就使得必须采用灵活的自组织和自同步模式。由前述可知，自组织和自同步讲起来容易，但很难以最好的方式实现。特别是对 $C^2$ 的灵活性的控制必须限于某个程度，否则会产生混乱的行为。通常， $C^2$ 过程需要采用两种不同的控制机制：第一是简单规则和算法的底层交互机制，它对于确定的意图能够产生基于态势变化的系统变化；第二是需要采用一个自顶向下聚焦于作战意图的 $C^2$ 过程来抑制这些变化。由于信息时代的战斗力取决于信息化武器装备，特别是指挥信息系统对人的支持能力，因此在一个更广泛的意义上，



$C^2$  显现出由表 2.4 表述的复杂性因素与信息时代战斗力之间的关系。

表 2.4 复杂性因素与信息时代战斗力之间的关系

复杂性因素	信息时代战斗力
非线性交互	战斗力由大量非线性交互行为产生
分布式控制	战斗力来源于每个作战单元的自主控制，不存在指挥每个行动和作战单元的主导者
自组织	使通常出现混乱的局部行动变成所需范围的有序行动
非对称次序	与对称性相差甚远的军事冲突，局部效能的相关性是生成战斗力的关键
自适应性	作战力量必须适应一个变化的环境并在其中协同开展作战活动
集体动态行为	作战单元与指挥机构之间存在连续的反馈

## 2. $C^2$ 建模与信息融合

当前，讨论 NCW 认知和  $C^2$  过程的许多文献都认为描述 NCW 中的  $C^2$  过程应采用一个复杂自适应系统（Complex Adaptive System, CAS）建模方法。该系统要能够理解多类 CAS 需求，才能预测它们的宏观行为，因为该宏观行为来源于该系统对各微观行为的预测结果的综合。当前，我们特别希望采用 CAS 方法设计和构建一个有界应急行为的  $C^2$  过程系统（称为 CAS/ $C^2$  系统），使理论上的理解（预测）最符合具体的  $C^2$  或任务目标。许多 CAS/ $C^2$  文献认为  $C^2$  过程“在其混沌边缘上理想地运行”，该边缘构成了固有的 CAS/ $C^2$  过程的一个有用的、可预测的宏观行为边界，且不会使  $C^2$  过程产生倾覆性混乱行为。

鉴于信息融合是为作战决策和  $C^2$  操作提供支持信息的过程，因此对于信息融合设计者来说，最重要的是理解需要其提供信息的非线性决策支持环境。获取信息融合与非线性决策环境的依赖关系的一个途径是借助多代理系统（MAS）结构，其中各代理反映了 CAS/ $C^2$  的不同研究与应用方向。已见到采用智能代理研究战争中的应急行为的例子有，取自美国海军作战发展指挥（U.S. Marine Corps Combat Development Command, MCCDC）题目（Albert 研究项目<sup>[34]</sup>的一部分）的“不能分解的半自主自适应作战（Irreducible Semi-Autonomous Adaptive Combat, ISAAC）系统”<sup>[32]</sup>研究成果，以及增强的 ISAAC 神经模拟工具包（Enhanced ISAAC Neural Simulation Toolkit, EINStein）。使用代理研究 CAS 还有一些其他的实验案例<sup>[33,35,36]</sup>，已经用于辅助开发洞察 CAS 行为和作战过程各类研究中。还有一些研究和开发 CAS 与数据融合相互依赖关系的方法。总体来说，这些研究和设计采用的知识很有限，并且缺乏健壮性领域的研究。

关于 NCW 指挥控制中信息融合的其他方法，还有“弹性误差数据融合（Error-Resilient Data Fusion, ERDF）”<sup>[37]</sup>，其中提供数据的各方使用表决程序形成一个综合态势估计。在 ERDF 方法中，用来表示和聚集表决结果的系统特征是能够获得一个称为“误差弹性聚集输出（Error Resilient Collective Outcomes, ERCO）”的高生成概率。当选择该表决过程产生一个可靠的 ERCO 时，尚未完成的表决和没有过时的数据都不能改变该聚集推理结果，这充分说明 ERDF 能够产生一个健壮的结论或态势说明。这样的 ERCO 结果为代理在缺少关键数据的情况下能够立刻采取行动奠定了基础，从而可以适应环境的变化。此外，还有关于信息融合和网络设计的 CAS 的可选方法研究也取得了一定成果，如生物医学方面令人鼓

舞的研究方法<sup>[37,38]</sup>。但总的说来,信息融合学界尚未建立一个系统研究策略来开发 CAS 所涉及的关系中的信息融合功能和过程。

## 2.6 分布式信息融合中的挑战性问题

信息时代的各类专业应用活动依赖于信息基础设施,而其核心是信息网络。因此,可以预期,不仅军事应用,而且商业、工业、农业、金融等各类民用业务系统都将在一个基于网络为中心的关系中运行。如本章前几节所述,使用信息网络会带来各专业领域能力的显著提升,因此如何设计符合相应专业应用需求的物理网络和信息融合模式,以在相应业务系统运行中产生预期的能力,达到相应的效用目标,成为不可避免的问题。

本章给出的网络中心(或网络中心战 NCW)价值链的概念、流程和实现框架具有通用意义,在不同的业务应用中,可以通过植入委托过程和连接(交互)协议,改善所需要的感知信息质量和信息/态势共享能力以及功能交互能力。然而,众所周知,对于为人提供支撑平台或工具的信息系统来说,特别是对于一个复杂系统的控制来说,必须有人参与。其中各功能模态之间的互动需要人的判断、决策和控制。例如,NCW 中的指挥与控制( $C^2$ )系统需采用 CAS 建模方法,其中特别需要将人的理解、判断等认知能力融入系统,这是信息融合学界设计更好的分布式融合系统必须认真研究和考虑的问题,以使融合系统在需要高适应性和非线性应用环境中成功运行。本章描述的关于认知概念及其本质以及网络(网络中心战)价值链中的自组织和自同步的概念和实现过程,都是为应对复杂的态势和环境所出现的不一致、应急和局部混乱状态而提出的,是对传统信息融合设计和开发需求的合理扩展,但尚未涉及面对典型非线性(非对称)态势和行为的彻底变革。

与集中式信息融合相比,NCW 中的分布式信息融合面对的主要挑战性问题有:

① 网络结构问题。在网络带宽、传输时延、过程噪声及融合精度约束下,设计使系统消耗资源最小、信息效用最大的网络连接方式并选择最优的信息传输路径。

② 信息重用产生的相关性问题。信息重用有两个内涵,一个是网络信息图中信息节点之间的多连接方式产生的某一上游节点信息为下游节点重复使用;另一个是多信源关注责任区的覆盖区域内同一目标信息的重复计入。这两种信息重用都会产生融合输入信息的相关性,导致融合误差协方差增长。该问题在集中式融合中已经出现,在分布式融合中已不可忽视。

③ 传感器优化协同问题。使网络中各节点的融合信息效能(信息量或信息精度)达极大的传感器协同问题,包括传感器如何协同探测分配、交接以及探测信息如何协同分发(即在网络中的传输途径)等,要考虑网络传输带宽、时延和精度约束。

④ 自利平台优化协调方法。在网络带宽约束和信号传输不断衰减的约束下,网络中各节点代理如何在平台局部效用和网络全局效用之间进行协调,包括向(从)哪个节点发送(接收)信息以获得最大信息增益,其中以付出代价(占用带宽)最小,获取效用(产生的精度增益)最大为目标。

⑤ 合作环境中的信用问题。指网络中各节点代理选择(信息)交互对象中的信用问题,

即基于节点对服务合同的完成和交付状况的统计结果评估节点信用,作为选择交互对象的依据,以使各节点和全局信息效用最大。

⑥ 人一代理集合体(HAC)问题。分布式融合必须解决计算资源(代理)与人的一系列交互合作关系,以使NCW中各节点的分布融合功能满足相应的作战节点的情报保障需求,人在其中起着主导作用。主要问题有:灵活的自治性(代理的自主行动与人的指导行动相结合)、HAC的自组织合作、合作激励准则、可度量的信息基础设施等。

⑦ 分布式估计算法。指适应不同应用网络结构的各类节点所采用的融合估计算法。特别针对②中所描述的两类情况产生的信息重复计入导致信息的相关性或相关性未知状态,如何建立、选择最优和次优融合估计算法以抑制融合误差协方差增长,这是分布式融合不同于集中式融合算法的关键问题,详见第4章。

⑧ 分布式融合应用算法。指网络环境下的分布式信号检测算法、分布式目标定位与跟踪算法、分布式目标分类(识别)算法、分布式态势估计与威胁分析算法、分布式融合试验与评估算法等。这些不同级别的分布式应用算法有些源于对相应集中式算法的改进,有些是分布式融合特用的新算法,详见第5章~第10章。

## 参考文献

- [1] 赵宗贵. 军事革命与联合作战. 中国电子学会C<sup>3</sup>I工程与技术专业委员会学术研讨会论文集, 2000.
- [2] 李成刚. 美军联合作战指挥体制改革的最终突破及启示——由海湾战争看《葛德华特—尼科尔斯国防部改组法》. 军事科学院, 2014年2期.
- [3] 马丁 J 戈尔曼, 亚历山大 克朗加德. 部门间合作的制度化: 美国政府的《葛德华特—尼科尔斯法案》. 王淑梅译. 载外国军事技术, 2005年11期.
- [4] 陈伯江. 美国高级将领与著名学者访谈录. 北京: 世界知识出版社, 1998.
- [5] Owens W A. May The emerging system of systems. U.S. Naval Institute Proceedings, 1995. (121): 36–39.
- [6] Department of Defence (DoD), USA, Joint vision 2020, Hune, 2000.
- [7] CJCSI 3151. 01A. Global Command and Control System Common Operational Picture Reporting Requirements. 19 January, 2003.
- [8] Evans P, T S Wurster. Blown to Bits: How the New Economics of Information Transforms Strategy. Boston, MA: Harvard Business Press, 2000.
- [9] Alberts D S, J J Garstka, R E Hayes, et al. Understanding Information Age Warfare. Washington, DC: CCRP Publications, 2001.
- [10] Porter M E. Competitive Advantage: Creating and Sustaining Superior Performance. New York: The Free Press, 1985.
- [11] Alberts D S, R E Hayes. Power to the edge. CCRP Program Monograph online, [http://www.dodccrp.org/vhtml4/books\\_downloads.html](http://www.dodccrp.org/vhtml4/books_downloads.html), 2003.
- [12] Evidence Based Research, Inc. Network centric operations conceptual framework version 1.0. 2003. Report

- prepared for Office of Force Transformation, November, 2003.
- [13] Weick K E. The Social Psychology of Organizing. Reading, MA: Addison-Wesley, 1969.
- [14] Alberts D S. Information age transformation. CCRP Program Monograph online, [http://www.dodccrp.org/html4/books\\_downloads.html](http://www.dodccrp.org/html4/books_downloads.html), 2002.
- [15] Alberts D S, R E Hayes. Understanding command and control. CCRP Program Monograph online, [http://www.dodccrp.org/html4/books\\_downloads.html](http://www.dodccrp.org/html4/books_downloads.html), 2006.
- [16] Sieck W R. FOCUS: A model of sensemaking. Technical Report 1200, <http://www.au.af.mil/au/awc/awcgate/army/tr1200.pdf>, May, 2007.
- [17] Zack M H. Managing organizational ignorance. Knowledge Directions, 1999, 1: 36–49.
- [18] McCaskey M B. The Executive Challenge: Managing Change and Ambiguity. Marshfield, MA: Pitman Publishers, 1982.
- [19] Rittel H, M Webber. Dilemmas in a general theory of planning. In: Policy Sciences, Amsterdam, the Netherlands: Elsevier Scientific Publishing Company, Inc. [Reprinted in N. Cross (Ed.). 1984. Developments in Design Methodology. Chichester, U.K.: John Wiley & Sons.], 1973, Vol. 4, 155–169.
- [20] Leedom D K. The analytic representation of sensemaking and knowledge management within a military C<sup>2</sup> organization. Air Force Research Laboratory Human Effectiveness Directorate Report, 2004.
- [21] Weick K E. Sensemaking in Organizations. Thousand Oaks, CA: Sage Publications, 1995.
- [22] Hammond S C, M L Sanders. Dialogue as social self-organization: An introduction. Emergence: Complexity and Organization, 2002, 4(4): 7–24.
- [23] Wheatley M. Leadership and the New Science: Learning about Organization from an Orderly Universe. San Francisco, CA: Berrett-Koehler, 1992.
- [24] Cebrowski A K, J J Garstka. Network centric warfare: Its origins and future. U.S. Naval Institute Proceedings, January, 1998, 124(1): 35.
- [25] Costanza C D. Self-Synchronization, the Future Joint Force and the United States Army's Objective Force. Monograph, Fort Leavenworth, KS: School of Advanced Military Studies United States Army Command and General Staff College, May, 2003.
- [26] Covey S. The Seven Habits of Highly Effective People: Powerful Lessons in Personal Change. New York: Fireside Publishers, 1990.
- [27] 海湾战争：美国国防部致国会的最后报告. 军事科学院外国军事研究部译. 北京：军事科学出版社，1992.
- [28] 赵宗贵, 熊朝华. 信息融合概念、方法与应用. 北京：国防工业出版社, 2012.
- [29] Van Laere J, M Nilsson, T Ziemke. Implications of a Weickian perspective on decision-making for information fusion research and practice. 10th International Conference on Information Fusion, Quebec City, Quebec, Canada, 2007.
- [30] Lundberg C G. Made sense and remembered sense: Sensemaking through abduction. Journal of Economic Psychology. 2000, 21(6): 691–709.

- 
- [31] Moffat J. Complexity Theory and Network Centric Warfare. Washington, DC: CCRP Press, 2003.
- [32] Ilachinski A. Irreducible semi-autonomous adaptive combat (ISAAC): An artificial-life approach to land combat. Military Operations Research, 1997, 5(3): 29.
- [33] Hummel J R, J H Christiansen, C M Macal, et al. The development of complex adaptive systems based decision support systems. Decision and Information Sciences Division, Argonne National Laboratory, Argonne, IL, 2005.
- [34] Ilachinski A. Towards a science of experimental complexity: An artificial-life approach to modeling warfare. Special issue of Kybernetes Journal, February, 1999.
- [35] Yang A, H A Abbass, R Sarker, et al. Network Centric Multi-Agent Systems: A Novel Architecture. The Artificial Life and Adaptive Robotics Laboratory, School of Information Technology and Electrical Engineering, University of New South Wales, Kensington, New South Wales, Australia, 2005.
- [36] Lauren M K. Modeling combat using fractals and the statistics of scaling systems. Military Operations Research, 2000, 5(3): 47–58.
- [37] Urken A B. Voting theory, data fusion, and explanations of social behavior. Paper from the AAAI 2011 Spring Symposium, Stanford, CA, 2011, 29–34.
- [38] Ferro M, G Pioggia. A biologically based framework for distributed sensory fusion and data processing. In: Sensor and Data Fusion, N. Milisavljevic (Ed.), Vienna, Austria: InTech, 2009.

# 第 3 章 分布式信息融合中的新 概念和新方法

## 3.1 引言

分布式信息融合来源于信息化环境中以网络为中心的应用对感知信息的需求,军事领域的分布式信息融合则来自分布式的网络中心战(NCW)模式与战场感知的紧密耦合需求。我们知道,基于网络的分布式系统的开放性和灵活性远远大于集中式系统,因此,分布式信息融合系统自身的开放性产生的开放信息交换和融合方式必然导致系统性能的降低,这是由于多次重复使用旧信息,未能充分观察一个或多个平台上的信息源的性能和特征(如噪声、与其他信息源的相关性等),未能识别信息源的可靠性(可信赖性)以及未能适当协调多信息源的运行状态等原因引起的。本章提出与分布式信息融合系统开放性有关的一些新问题,并且讨论在无法兼顾分布式信息融合系统的灵活性和可度量(可预测)性的裨益时,如何减少或消除这些问题以尽量获得最大的信息效用。

本章是依据文献[1]中的第 2 章和作者多年的研究与工作经验撰写的,主要内容包括:3.2 节介绍分布式信息融合概念和问题,这是本章的基础。分布式信息融合是一个由网络连接起来的多代理系统(Multi Agent System, MAS),其中每个代理都是某个大型信息网络中的探测节点、融合节点或判定节点。3.2 节所提出的 6 个问题是该 MAS 系统成功应用于工程实践所必须解决的,其中有的问题在集中式融合系统中已存在,但未引起重视或尚未起主导作用,而在开放性的分布式融合系统中则无法回避;还有的是在分布式网络环境中产生的新的必须解决的问题。3.3 节描述了有界协方差增长(Bounded Covariance Inflation, BCI)方法,该方法通过用独立的方差增长随机向量来取代相关的随机向量,以分析和控制由于信息重复使用引起的相关性。3.4 节介绍了传感器优化协同方法,描述了基于全局效用的极大和算法,以此来获得各传感器的最优检测与信息分发活动。3.5 节通过一个拍卖计算机制,基于资源占用(信道带宽、信息获取和分发)和传输信道衰减等约束来控制和管理各代理的自利行为,以获取全局最大信息效用。3.6 节给出了合作环境中的信用(Trust)模型,用来描述 MAS 中合作代理的履行承诺(合同)的可靠性(可信赖性)问题,并采用与 3.3 节给出的有界协方差增长(BCI)方法相结合的信用概率模型来求解这一问题,这对于选择可信合作对象或摒弃不可信合作对象至关重要,目的是获得全局最佳的信息效用。3.4 节到 3.6 节每一节都采用熟知的目标跟踪和传感器信息融合案例对相应方法进行验证。3.7 节给出了分布式融合系统未来必然要遇到的人—代理集合体(Human—Agent Collectives, HAC)问题,这是为决策和指挥控制提供支撑平台和工具的任何信息系统都面临的设计挑战问题,需要紧密交织

在一起的人和软件代理共同努力才能解决。文献[2]构建了一个用户参与的融合模型，它强调功能、过程和正规模型中的信息交互。

## 3.2 分布式信息融合概念与问题概述

分布式信息融合是指地理上分散配置并通过网络连接协同运行的感知系统，目标是获得信息优势，最终达到最佳效用。在达成分布式融合的多代理系统（MAS）中，可能存在多个承载平台，并且平台之间、代理之间可能有多个自组织关系，通过网络实现信息共享和功能交互。该 MAS 中的代理可以分为信息收集即信息源代理、信息处理代理和信息应用代理。每一类代理都基于应用需求以自主式、反应式或预设式等工作模式运行，它们都能够通过相应的信息处理改善信息质量。

我们以多平台多传感器实现多目标定位、识别与跟踪的战场感知系统为例说明分布式信息融合的概念。显然，这是一个分布式战场感知网络，其连接节点包括分散配置的探测传感器、信息融合处理节点和应用判定节点等三类，它们分别位于相应的平台上，基于任务需求的自组织关系进行网络连接，如图 3.1 所示。




图 3.1 分布式信息融合系统概念示例

对图 3.1 中的对象概念及功能说明如下：

- 代理（Agent），位于网络的融合节点和应用判定节点上，一个代理基于自身或其他代理连接的多个传感器的不精确测量，估计和跟踪其关注区域的目标；
- 平台（Stakeholder），含有代理节点和传感器探测节点，平台内和平台之间的节点可以基于自组织关系通过网络进行连接；
- 观测区域（Range Of Observe, ROO），指传感器对环境的观测范围，多传感器的roo可能相互覆盖；
- 关注区域（Range Of Interest, ROI），指传感器所关注的环境监视区域，或一个代理基于任务所关注的空间范围，又称为责任区。通常一个代理的ROI位于其ROO中，不同传感器的ROI可能相互覆盖；

- 组织关系 (Organization Relationship), 指基于感知任务设置的节点之间、平台之间的隶属、指挥或协同关系, 包括其间的信息交互 (共享和态势一致理解) 关系, 功能依赖关系及管理控制关系等;
- 交互 (Interaction) 关系, 指平台内或平台之间三类节点间的信息交换和功能控制关系。

下面描述分布式信息融合系统所面临的主要问题, 包括传统集中式信息融合已经出现但在应用中尚未产生重大影响或在融合学科中尚未引起重视的问题, 以及在网络中心战环境中出现的分布式信息融合新问题, 这些问题都是分布式信息融合研究和设计中无法回避、必须认真解决的问题, 主要有下述 6 个问题。

### (1) 独立性统计假设 (Statistical Hypothesis) 问题

集中式信息融合中的两个独立性假设是: 融合输入的不同来源信息相互独立; 同一来源不同时刻获取的信息相互独立。即使这两个独立性假设不成立, 也予以忽略, 从而成为集中式融合算法的前提条件。在分布式信息融合中, 融合节点的输入信息有传感器测量信息、其他融合节点的融合信息以及基于自身节点上一时刻融合结果的预测信息, 这三类信息通常不是统计独立的或统计独立性未知, 这一点在分布式融合中是不能忽略的。

从某种意义上讲, 解决融合信息的相关性成为分布式融合算法面对的首要问题。顺便指出集中式融合算法和分布式融合算法中相关性概念的差异: 集中式融合中的相关性与关联概念类似, 是指判定级的关联; 而在分布式融合中, 相关性是指信息之间的统计独立性。

### (2) 信息重用 (Information Recycling) 问题

信息重用现象的产生在概念上有三个来源。重用信息的第一个来源是指在一个网络信息图中, 两个信息节点之间可能存在多条路径, 称为多连接, 如图 3.2 所示。




图 3.2 带反馈的多连接示例

从图 3.2 可以看出, 局部节点  $F_1$  的  $\bar{L}$  时刻点信息 (探测信息或融合信息) 通过两个路径传输到自身的  $L_1$  时刻点, 如果忽略传输时间的差异,  $L_1$  点进行信息融合时, 两次使用了  $\bar{L}$  点的信息, 而对于节点  $F_1$  的  $L_1$  点的下一时刻点的信息融合来说, 则三次使用了  $\bar{L}$  点的信息。这里  $\bar{L}$  称为上游共用节点, 其信息可为下游多个节点 (如该图中的  $L_1$ 、 $H$ ) 使用或重复使用。在一个上游共用节点信息被某一下游节点重复使用多次的情况下, 并未增加任何新的有效信息却出现传输带宽增加和相关噪声的多次影响, 导致融合误差协方差增长, 进而产生不一致的战场态势并可能使后续的作战决策出现失误。重用信息的第二个来源是两个数据源 (跟踪



节点)的关注区域(ROI)相互覆盖时,传感器对覆盖区中的目标探测信息要传送给这两个数据源,下游节点对这两个数据源信息进行融合时就会产生对该覆盖区内目标探测信息的重复使用。重用信息的第三个来源是当两个信息源(传感器)的信息收集(探测)过程相互依赖(非统计独立)时,也会产生一定程度的信息重用。如果获得了关于分布式信息传输结构(信息图)和数据源相互覆盖知识,第一个和第二个重用信息来源是显式的,通常表现为共用先验信息,可以通过改变网络结构或者采用某些算法去除重用信息。第三个重用信息来源通常是由于目标状态中的共用过程噪声或关于信息来源的知识(如数据谱系)不完备产生的,通常是隐式的,比较难于去除。

### (3) 融合输入信息选用判定问题 (Information Selection and Decision)

在网络环境中,为使某节点集中融合产生优化的信息增益,应具备的条件有:①较大的通信带宽(没有时延或具有可容忍的延误);②输入信息是独立获取的;③输入信息误差(测量误差和动态噪声或二者的估计误差协方差)较大。其中①、②在许多融合模型中都作为前提假设提出,而③则尚未列入考虑,但其确实有很大影响,如图 3.3 所示。




图 3.3 基于过程噪声和通信速率的层次融合性能

图 3.3 中坐标横轴表示输入信息误差(噪声或融合误差协方差),纵轴  $A/A^*$  表示融合输出误差椭圆面积与输入的单源信息误差椭圆面积均值之比,  $n=i$  表示信息传输延迟  $i-1$  个测量周期( $i=1,2,4,8$ )。从该图可以看出,融合信息的相对误差随输入信息误差的增大而减小,这就说明,对大误差信息进行融合能产生较大的增益。当输入信息是精确的或误差较小时,信息融合无法体现其信息增益优势,甚至会出现与信息重用类似的大带宽占用和融合负增益后果。因此,尽量减少精确信息和小误差信息的输入量,成为选择和控制在融合输入信息的重要准则。关于输入信息选择的另一个准则在第 8 章给出,即精度相近信息融合会产生较大的信息增益,而精度相差较大信息融合会与真值渐行渐远。

### (4) 传感器协同 (Sensor Coordination) 问题

在 NCW 环境中,一个分布式融合系统无法达到集中式融合效能,只能基于其连接的各传感器观测范围(ROO)的测量来获得对其关注范围(ROI)内对象的次优信息。原因之一是通信带宽和传输延迟限制了传感器探测信息的分发能力,使得分布式融合无法采用传感器

对所有融合代理的无延迟测量播放式结构达到测量信息充分共享;原因之二是无法采用高效的误差校验代码,将传感器测量无误差地传输给相应的融合节点;原因之三是传输功率的限制以及传输信道的衰减。为了在有限的系统资源约束下获得满足作战应用需求的信息质量,需要在目标信息获取和分发环节进行传感器协同,主要有:①将 ROI 中目标与作战节点任务需求相联系进行传感器系统部署和探测平台机动控制;②基于信息效用(目标精度或信息量)需求对每个传感器探测状态进行控制,包括休眠/活动、传感器探测指向以及传感器工作参数调整;③对传感器测量信息在网络中的传输路径进行选择,既要选择传感器个体状态,又要选择传感器之间的连接状态,以获得网络探测系统的全局效用极大化。

在无线传感器网络(Wireless Sensor Network, WSN)中,传感器还应具有自组织和间接的协同能力,包括对邻近节点的感知、局部网络连接、叶节点与根结点之间的信息交互以及干节点的信息上报状态,这就更需要选择尽可能少的工作状态使 WSN 的整体效能达到最佳。

#### (5) 自利平台的协调(Coordination For Selfish Stakeholders)问题

在一个异构(异介质、异性能、异信息业务应用)的分布式信息系统中,不同种类的平台上的代理或不同的节点代理可能具有不同的服务对象并达到基于信息效用(信息量或信息质量,以及最佳的局部信息服务)的不同目标。为此,各代理必然展开对网络资源和信息资源的竞争。如果听任各平台(或节点)代理们的局部自利行为,而不是在设计上采取限制措施,那么该分布式信息融合系统达到的全局目标很可能是这些代理们进行资源竞争产生的折中结果,这可能与期望达到的全局优化目标相差甚远。

这是一个典型的多代理系统(MAS)的综合优化问题。解决该挑战性问题的前提条件是竞争的各代理都要具有利他的意愿,从而构建一个合作环境。这样,所设计的分布式系统要使期望的系统开放性产生于各自利代理之间的交互行为之中。为尽可能达到系统开放性产生的最大增益,各自利代理在交互中既要有局部自利考虑,还要有全局利他考虑,各代理考虑的因素主要有:①占用系统资源(包括网络带宽资源和从其他代理获取的信息资源)需付出的代价(负支付);②提供信息资源获得的收益(指向其他代理提供信息获得的正支付);③产生的信息增益,指通过网络从自身和其他代理获取的信息产生的信息量或精度增益;④基于传输信道衰减考虑提供的信息最多可能惠及的节点,以获取最大的正支付。在这4类因素的约束下,求取系统中各代理之间的最佳信息传输(信息交互共享)路径,使该 MAS 的全局信息增益达到极大。

#### (6) 合作对象的信用(Collaborator's Trust)问题

分布式融合系统中的信用指基于一个代理履行与其他代理的合作协议情况(指对协议规定的信息服务内容和指标的完成情况)产生的对该代理的可信赖程度。一个 MAS 中的一个或多个代理可能由于故障、偏差或出于蓄意形成较低的信用而不受信任。为了使一个代理能够有代表性地择优选取合作对象,必须建立合作环境中的对象(代理)信任模型,估计一个合作对象按合作协议成功交付信息服务的概率向量及其误差协方差,以识别出具有较低信用的代理,并在合作对象中集中予以剔除;否则,分布式信息融合系统的开放性会使它们的错误信息传播给其他代理并很快污染整个系统。与此同时,一个代理必须能够估计自己向其他

代理提供信息服务的信用，以尽可能取得自己作为可信赖信息源的声誉。

### 3.3 控制相关信息融合误差的有界协方差增长方法

这里的相关性描述并非独立测量或估计信息，它们具有完全相同或部分相同的信息内容。

在这个相关性定义下，相关信息的融合就是指同一信息的多次重复使用，或者在融合中使用具有一定相同内容的多个非独立相关信息，它既涉及网络带宽资源的重复占用，又会产生融合误差协方差增长。因此，在分布式融合系统中必需对它认真分析并进行控制。

#### 3.3.1 有界协方差增长控制方法的概念和应用背景

有界协方差增长（Bounded Covariance Inflation, BCI）方法在概念上是指用两个保守的独立随机向量取代两相关（或相关性未知）随机向量，以简化对相关随机向量融合误差的分析和控制。这里保守的概念是指这两个独立随机向量的协方差矩阵要大于被代替的两相关随机向量的协方差矩阵。协方差矩阵尺度的度量指标主要有：矩阵行列式的绝对值、矩阵特征值之和或最大特征值，以及矩阵对角元素平方和等，两矩阵尺度比较可以考虑它们的差矩阵的正定性。

提出并应用 BCI 方法的背景如下：

- 为消除信息网络中上游共用节点信息为下游某一节点重复使用产生的融合输入信息的相关性，可以通过将融合信息图由多连接结构改变为单连接结构以避免信息重用，但这需要额外记录和积累信息传输路径以识别共用信息节点，这会导致存储和占用带宽的增加；
- 融合节点面对的应用任务可能不允许变更信息图，否则会产生支持某代理应用任务的信息损失，必须采用其他手段和方法控制相关性引起的融合误差增长；
- 对非独立相关信息和确定性/小误差相关信息的输入进行控制，但难以确定输入信息相关性控制准则，特别是在信息重用产生的信息融合误差协方差增长与统计独立信息的集中式融合产生的信息精度增益之间如何权衡，这是迄今为止仍无法解决的问题；
- 许多专业领域都涉及相关信息或相关性未知信息的处理，为了应用已有的非相关信息处理模型和方法，用非相关信息取代相关或相关性未知信息的 BCI 方程是一种可选的技术途径。

#### 3.3.2 BCI 模型<sup>[3]</sup>

首先给出保守的误差协方差矩阵的概念：

随机向量的估计误差  $\tilde{\mathbf{u}} = \hat{\mathbf{u}} - \mathbf{u}$  的协方差矩阵  $\mathbf{P}_{uu}^*$  是保守的，即

$$\mathbf{P}_{uu}^* \geq E[\tilde{\mathbf{u}}\tilde{\mathbf{u}}^T] \quad (3.1)$$

也就是说矩阵  $\tilde{\mathbf{P}} = \mathbf{P}_{uu}^* - E[\tilde{\mathbf{u}}\tilde{\mathbf{u}}^T]$  是半正定的。这里的矩阵  $\tilde{\mathbf{P}}$  是半正定的系指该矩阵是所有特征值都不小于零的实对称矩阵， $n$  阶半正定的重要条件是： $\det \tilde{\mathbf{P}} = 0$ ，所有主子式

$\tilde{P} \geq 0, i=1, 2, \dots, n-1$ 。

下面我们以二维随机向量  $\mathbf{u} = (x, y)^T$  为例描述 BCI 模型。

(1) 估计误差交叉协方差  $\mathbf{P}_{xy}$  的有界约束公式

设二维随机向量  $\mathbf{u} = (x, y)^T$  的估计误差协方差矩阵为

$$\mathbf{P} = \begin{bmatrix} \mathbf{P}_{xx} & \mathbf{P}_{xy} \\ \mathbf{P}_{yx} & \mathbf{P}_{yy} \end{bmatrix} \quad (3.2)$$

式中, 对角元素  $\mathbf{P}_{xx}$  和  $\mathbf{P}_{yy}$  是分量  $x$  与  $y$  的方差, 非对角元素  $\mathbf{P}_{xy} = \mathbf{P}_{yx}^T$  是分量  $x$  与  $y$  的估计误差交叉协方差。

首先描述交叉协方差  $\mathbf{P}_{xy}$  的有界性。

在关于二维随机向量的BCI方法中, 保守的估计误差协方差矩阵  $\mathbf{P}$  可仅由对角元素  $\mathbf{P}_{xx}$  和  $\mathbf{P}_{yy}$  确定。此时, 交叉协方差  $\mathbf{P}_{xy}$  未知但有界:

$$[\mathbf{P}_{xy} - \mathbf{D}_{xy}]^T \mathbf{P}_{xx}^{-1} [\mathbf{P}_{xy} - \mathbf{D}_{xy}] \leq S^2 \mathbf{P}_{yy} \quad (3.3)$$

式中,  $\mathbf{D}_{xy}$  是  $\mathbf{P}_{xy}$  的“中心矩阵”, 它位于交叉协方差  $\mathbf{P}_{xy}$  可能变化范围的“中心”;  $S$  是  $\mathbf{P}_{xy}$  的散度, 又称  $\mathbf{P}_{xy}$  的散布边界。通常通过使  $S$  达到极小来选择  $\mathbf{D}_{xy}$ , 当  $\mathbf{D}_{xy} = 0$  时,  $S$  表示随机向量  $x$  与  $y$  的相关系数。

二维向量估计误差协方差  $\mathbf{P}$  的椭圆范围随交叉协方差  $\mathbf{P}_{xy}$  的变化情况如图3.4所示。




图 3.4 二维向量估计误差协方差  $\mathbf{P}$  的椭圆范围随交叉协方差  $\mathbf{P}_{xy}$  的变化情况

图 3.4 中,  $\mathbf{P}$  中各元素为  $\mathbf{P}_{xx} = 2$ ,  $\mathbf{P}_{yy} = 1$ ,  $\mathbf{P}_{xy}$  在  $[0.2, 0.8]$  区间变化。此时表示协方差矩阵  $\mathbf{P}$  的误差椭圆族为

$$(x, y) \begin{bmatrix} 2 & \rho \\ \rho & 1 \end{bmatrix} \begin{pmatrix} x \\ y \end{pmatrix} = 1 \quad 0.2 \leq \rho \leq 0.8$$

图 3.4 中, 各细虚线表示  $\mathbf{P}_{xy}$  在  $[0.2, 0.8]$  中变化形成的协方差矩阵  $\mathbf{P}$  的椭圆族, 粗虚线为中心椭圆 ( $\mathbf{D}_{xy}$  对应的椭圆)。外部实线是一个保守的协方差椭圆, 其对应的估计误差协方差矩阵为

$$\mathbf{P} = \begin{bmatrix} 1.3\mathbf{P}_{xx} & 0.5 \\ 0.5 & 1.3\mathbf{P}_{yy} \end{bmatrix}$$

下面导出  $\mathbf{P}_{xy}$  的边界约束条件。

将式 (3.2) 所示的二维随机向量估计误差协方差矩阵  $\mathbf{P}$  中的对角元素之逆  $\mathbf{P}_{xx}^{-1}$  和  $\mathbf{P}_{yy}^{-1}$  (也是正定对称矩阵) 进行球矩阵 (Sphering Matrix) 分解, 得:

$$\mathbf{P}_{xx}^{-1} = \mathbf{R}_{xx}^T \mathbf{R}_{xx} \quad \mathbf{P}_{yy}^{-1} = \mathbf{R}_{yy}^T \mathbf{R}_{yy}$$

代入式 (3.3) 得:

$$(\mathbf{P}_{xy} - \mathbf{D}_{xy})^T \mathbf{R}_{xx}^T \mathbf{R}_{xx} (\mathbf{P}_{xy} - \mathbf{D}_{xy}) \leq S^2 (\mathbf{R}_{yy}^T \mathbf{R}_{yy})^{-1} = S^2 \mathbf{R}_{yy}^{-1} (\mathbf{R}_{yy}^T)^{-1} \quad (3.4)$$

式中球矩阵  $\mathbf{R}_{xx}$  在概念上是指其能够将表示向量  $\mathbf{x}$  的椭圆  $\mathbf{x}^T \mathbf{P}_{xx}^{-1} \mathbf{x} \leq L$  转换为球形包络  $\mathbf{z}^T \mathbf{z} \leq L$ , 这里  $\mathbf{z} = \mathbf{R}_{xx} \mathbf{x}$ 。

将式 (3.4) 两端左乘  $\mathbf{R}_{yy}$ , 右乘  $\mathbf{R}_{yy}^T$ , 得

$$[\mathbf{R}_{xx} (\mathbf{P}_{xy} - \mathbf{D}_{xy}) \mathbf{R}_{yy}^T]^T [\mathbf{R}_{xx} (\mathbf{P}_{xy} - \mathbf{D}_{xy}) \mathbf{R}_{yy}^T] \leq S^2 \mathbf{I} \quad (3.5)$$

再援引矩阵形式的柯西—布尼亚可夫斯基不等式 (又称许瓦茨不等式):  $(\mathbf{x}^T \mathbf{A} \mathbf{y})^2 \leq (\mathbf{x}^T \mathbf{A} \mathbf{x})(\mathbf{y}^T \mathbf{A} \mathbf{y})$ , 即双线性二次型的平方小于各自二次型之积。在该不等式中取  $\mathbf{A} = \mathbf{R}_{xx}^T (\mathbf{P}_{xy} - \mathbf{D}_{xy}) \mathbf{R}_{yy}$ , 并取  $\mathbf{x} = \bar{\mathbf{x}}, \mathbf{y} = \bar{\mathbf{y}}$ , 皆为单位向量, 则式 (3.5) 变换如下:

$$\begin{aligned} |\bar{\mathbf{x}}^T \mathbf{R}_{xx}^T (\mathbf{P}_{xy} - \mathbf{D}_{xy}) \mathbf{R}_{yy} \bar{\mathbf{y}}|^2 &\leq |\bar{\mathbf{x}}^T \mathbf{R}_{xx}^T (\mathbf{P}_{xy} - \mathbf{D}_{xy}) \mathbf{R}_{yy} \bar{\mathbf{x}}| \cdot |\bar{\mathbf{y}}^T \mathbf{R}_{xx}^T (\mathbf{P}_{xy} - \mathbf{D}_{xy}) \mathbf{R}_{yy} \bar{\mathbf{y}}| \\ &\leq S^2 \|\bar{\mathbf{x}}\| \cdot \|\bar{\mathbf{y}}\| = S^2 \\ |\bar{\mathbf{x}}^T \mathbf{R}_{xx}^T (\mathbf{P}_{xy} - \mathbf{D}_{xy}) \mathbf{R}_{yy} \bar{\mathbf{y}}| &\leq S \end{aligned} \quad (3.6)$$

式 (3.6) 就是关于二维相关随机向量估计误差分析的 BCI 方法中交叉协方差  $\mathbf{P}_{xy}$  的有界约束条件, 注意其中的边界  $S$  尚未确定。

## (2) 二维 BCI 保守的协方差增益矩阵

在上述准备性描述之后, 可以证明<sup>[3]</sup>, 对于式 (3.2) 表示的二维随机向量的估计误差协方差矩阵  $\mathbf{P}$ , 能够找到一个保守的误差协方差矩阵  $\mathbf{P}_{\text{BCI}}^*$ :

$$\mathbf{P}_{\text{BCI}}^* = \begin{bmatrix} (1+KS)\mathbf{P}_{xx} & 0 \\ 0 & (1+S/K)\mathbf{P}_{yy} \end{bmatrix} \quad (3.7)$$

式中, 正值  $K$  称为增长因子, 通常使该协方差矩阵的行列式或迹达极小来确定;  $S$  是交叉协方差  $\mathbf{P}_{xy}$  的边界。从式 (3.7) 可以看出, 求取两相关随机向量估计误差的保守有界协方差增长矩阵  $\mathbf{P}_{\text{BCI}}^*$  的问题就归结为如何确定交叉协方差  $\mathbf{P}_{xy}$  和约束边界  $S$  的问题。

对几种情况讨论如下:

线性变换  $\mathbf{u} = \mathbf{F}(\mathbf{x}, \mathbf{y})$  不会改变协方差矩阵的保守性, 即

$$\text{若 } \hat{\mathbf{u}} = \mathbf{F}(\hat{\mathbf{x}}, \hat{\mathbf{y}}), \text{ 则 } \mathbf{P}_{uu}^* = \mathbf{F} \mathbf{P}^* \mathbf{F}^T$$

这是由于  $\mathbf{P}_{uu}^* = \mathbf{F} \mathbf{P}^* \mathbf{F}^T \geq \mathbf{F} \mathbf{P} \mathbf{F}^T = \mathbf{P}_{uu}^*$ ,  $\mathbf{P}$  和  $\mathbf{P}^*$  分别为二维随机向量估计  $(\hat{\mathbf{x}}, \hat{\mathbf{y}})$  的误差协方差矩阵和相应的保守误差协方差矩阵。

假设随机向量估计  $\hat{\mathbf{x}}, \hat{\mathbf{y}}$  不相关, 注意其保守的 BCI 矩阵 (3.7) 中的两对角元素  $\mathbf{P}_{xx}$  和  $\mathbf{P}_{yy}$  的表达式, 采用传统融合方法 (如卡尔曼滤波) 对  $(\hat{\mathbf{x}}, \hat{\mathbf{y}})$  及  $(\mathbf{P}_{xx}, \mathbf{P}_{yy})$  进行融合, 可得融合估计向量  $\hat{\mathbf{u}}$  及其误差协方差矩阵  $\mathbf{P}_{uu}$  满足下述方程:

$$\mathbf{P}_{uu}^{-1}\hat{\mathbf{u}} = \frac{\mathbf{P}_{xx}^{-1}\hat{\mathbf{x}}}{1+KS} + \frac{\mathbf{P}_{yy}^{-1}\hat{\mathbf{y}}}{1+(S/K)} \quad \mathbf{P}_{uu}^{-1} = \frac{\mathbf{P}_{xx}^{-1}}{1+KS} + \frac{\mathbf{P}_{yy}^{-1}}{1+(S/K)} \quad (3.8)$$

当  $S=0$  时, 我们重新获得非相关卡尔曼滤波的费舍尔 (Fisher) 信息矩阵形态<sup>[4]</sup>:

$$\begin{aligned} \mathbf{P}_{uu}^{-1}\hat{\mathbf{u}} &= \mathbf{P}_{xx}^{-1}\hat{\mathbf{x}} + \mathbf{P}_{yy}^{-1}\hat{\mathbf{y}} \\ \mathbf{P}_{uu}^{-1} &= \mathbf{P}_{xx}^{-1} + \mathbf{P}_{yy}^{-1} \end{aligned} \quad (3.9)$$

式 (3.9) 即为凸组合融合公式。

若  $S=1$  并取  $K = \frac{\omega}{1-\omega}$  ( $\omega \in [0,1]$ ), 即在相关性未知情况下, 概率分布采用指数权重,

融合概率为  $P(x) = \mathbf{C}^{-1}P_1^\omega(x)P_2^{1-\omega}(x)$ ,  $\omega = \frac{1}{1+K^{-1}}$ ,  $1-\omega = \frac{1}{1+K}$ , 故得:

$$\begin{aligned} \mathbf{P}_{uu}^{-1}\hat{\mathbf{u}} &= (1-\omega)\mathbf{P}_{xx}^{-1}\hat{\mathbf{x}} + \omega\mathbf{P}_{yy}^{-1}\hat{\mathbf{y}} \\ \mathbf{P}_{uu}^{-1} &= (1-\omega)\mathbf{P}_{xx}^{-1} + \omega\mathbf{P}_{yy}^{-1} \end{aligned} \quad (3.10)$$

于是我们重新获得协方差交集 (CI) 融合公式<sup>[5]</sup>。

### (3) 交叉协方差边界 $S$ 的确定

两相关随机向量  $\mathbf{x}$ 、 $\mathbf{y}$  的估计  $\hat{\mathbf{x}}$ 、 $\hat{\mathbf{y}}$  通过格拉姆—史密特正交化分解<sup>[6, 7]</sup>, 可以得到由正交随机向量  $\boldsymbol{\alpha}$ 、 $\boldsymbol{\beta}_x$ 、 $\boldsymbol{\beta}_y$  表示的形式:

$$\begin{aligned} \hat{\mathbf{x}} &= \mathbf{C}_{x\alpha}\mathbf{P}_\alpha^{-1}\boldsymbol{\alpha} + \boldsymbol{\beta}_x \\ \hat{\mathbf{y}} &= \mathbf{C}_{y\alpha}\mathbf{P}_\alpha^{-1}\boldsymbol{\alpha} + \boldsymbol{\beta}_y \end{aligned} \quad (3.11)$$

式中,  $\boldsymbol{\alpha}$  和  $\mathbf{P}_\alpha$  是两估计的共用信息 (即相关信息  $\boldsymbol{\alpha}$  及其方差  $\mathbf{P}_\alpha$ ),  $\mathbf{C}_{x\alpha}$  和  $\mathbf{C}_{y\alpha}$  分别为  $\mathbf{x}$  与  $\boldsymbol{\alpha}$ ,  $\mathbf{y}$  与  $\boldsymbol{\alpha}$  的交叉协方差。由于  $\boldsymbol{\beta}_x$  与  $\boldsymbol{\beta}_y$  是正交的, 不难得到  $\hat{\mathbf{x}}$  与  $\hat{\mathbf{y}}$  的交叉协方差为

$$\mathbf{P}_{xy} = \mathbf{C}_{x\alpha}\mathbf{P}_\alpha^{-1}\mathbf{C}_{y\alpha} = \left[ \mathbf{C}_{x\alpha}\sqrt{\mathbf{P}_\alpha^{-1}} \right] \left[ \mathbf{C}_{y\alpha}\sqrt{\mathbf{P}_\alpha^{-1}} \right]^T \quad (3.12)$$

将式 (3.12) 代入式 (3.4) 左端, 并取  $\mathbf{D}_{xy} = 0$ , 再应用方差形式的许瓦茨不等式 (二向量协方差小于各自根方差之积:  $\text{cov}(x, y) \leq \sqrt{D(x)} \cdot \sqrt{D(y)}$ ), 并视

$$\mathbf{C}_{\alpha x}\mathbf{P}_\alpha^{-\frac{1}{2}}\mathbf{R}_{xx}\bar{\mathbf{x}} = \mathbf{x}, \quad \mathbf{C}_{\alpha y}\mathbf{P}_\alpha^{-\frac{1}{2}}\mathbf{R}_{yy}\bar{\mathbf{y}} = \mathbf{y}$$

可以得到:

$$\begin{aligned} \left| \bar{\mathbf{x}}\mathbf{R}_{xx}^T\mathbf{P}_{xy}\mathbf{R}_{yy}\bar{\mathbf{y}} \right| &= \left| \bar{\mathbf{x}}\mathbf{R}_{xx}^T \left[ \mathbf{C}_{x\alpha}\mathbf{P}_\alpha^{-\frac{1}{2}} \right] \left[ \mathbf{C}_{y\alpha}\mathbf{P}_\alpha^{-\frac{1}{2}} \right]^T \mathbf{R}_{yy}\bar{\mathbf{y}} \right| \\ &= \left| \left[ \mathbf{C}_{\alpha x}\mathbf{P}_\alpha^{-\frac{1}{2}}\mathbf{R}_{xx}\bar{\mathbf{x}} \right]^T \left[ \mathbf{C}_{\alpha y}\mathbf{P}_\alpha^{-\frac{1}{2}}\mathbf{R}_{yy}\bar{\mathbf{y}} \right] \right| \\ &\leq \sqrt{\left[ \mathbf{C}_{\alpha x}\mathbf{P}_\alpha^{-\frac{1}{2}}\mathbf{R}_{xx}\bar{\mathbf{x}} \right]^T \left[ \mathbf{C}_{\alpha x}\mathbf{P}_\alpha^{-\frac{1}{2}}\mathbf{R}_{xx}\bar{\mathbf{x}} \right]} \times \sqrt{\left[ \mathbf{C}_{\alpha y}\mathbf{P}_\alpha^{-\frac{1}{2}}\mathbf{R}_{yy}\bar{\mathbf{y}} \right]^T \left[ \mathbf{C}_{\alpha y}\mathbf{P}_\alpha^{-\frac{1}{2}}\mathbf{R}_{yy}\bar{\mathbf{y}} \right]} \\ &\leq \sqrt{\max \text{eig} \left[ \mathbf{R}_{xx}^T\mathbf{C}_{x\alpha}\mathbf{P}_\alpha^{-1}\mathbf{C}_{\alpha x}\mathbf{R}_{xx} \right]} \times \sqrt{\max \text{eig} \left[ \mathbf{R}_{yy}^T\mathbf{C}_{y\alpha}\mathbf{P}_\alpha^{-1}\mathbf{C}_{\alpha y}\mathbf{R}_{yy} \right]} \end{aligned} \quad (3.13)$$

式中,  $\max \text{eig} \mathbf{B}$  表示矩阵  $\mathbf{B}$  的最大特征值。该式最后一个不等号来源于关于标准二次型的不等式<sup>[9]</sup>

$$\mathbf{x}^T \mathbf{B} \mathbf{x} = \sum_{i=1}^n \lambda_i x_i^2 \leq \lambda_1 \quad (3.14)$$

式中,  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n$  为  $\mathbf{B}$  的  $n$  个实特征值,  $x_i$  为相应特征向量, 满足  $\sum_{i=1}^n x_i^2 = 1$ 。分别取  $\mathbf{B} = \mathbf{R}_{xx}^T \mathbf{C}_{x\alpha} \mathbf{P}_{\alpha}^{-1} \mathbf{C}_{\alpha x} \mathbf{R}_{xx}$  和  $\mathbf{B} = \mathbf{R}_{yy}^T \mathbf{C}_{y\alpha} \mathbf{P}_{\alpha}^{-1} \mathbf{C}_{\alpha y} \mathbf{R}_{yy}$ , 就得到式 (3.13) 右端两因子如下:

$$\begin{aligned} \Omega_{x\alpha} &= \sqrt{\max \text{eig} \left[ \mathbf{R}_{xx}^T \mathbf{C}_{x\alpha} \mathbf{P}_{\alpha}^{-1} \mathbf{C}_{\alpha x} \mathbf{R}_{xx} \right]}, \text{称为 } x \text{ 的耦合量} \\ \Omega_{y\alpha} &= \sqrt{\max \text{eig} \left[ \mathbf{R}_{yy}^T \mathbf{C}_{y\alpha} \mathbf{P}_{\alpha}^{-1} \mathbf{C}_{\alpha y} \mathbf{R}_{yy} \right]}, \text{称为 } y \text{ 的耦合量} \end{aligned} \quad (3.15)$$

于是可知, 当一个代理接收来自其他代理的两个消息 (含状态向量  $\mathbf{x}$ 、 $\mathbf{y}$  和方差矩阵  $\mathbf{P}_{xx}$ 、 $\mathbf{P}_{yy}$ ) 时, 这两个消息的交叉相关边界就是

$$S = \Omega_{x\alpha} \times \Omega_{y\alpha} \quad (3.16)$$

基于以上推导结果, 得到两随机向量交叉相关边界的计算过程如下:

- 对相关随机向量  $\hat{\mathbf{x}}$ 、 $\hat{\mathbf{y}}$  进行正交化分解, 获得共用信息  $\alpha$  和  $\mathbf{P}_{\alpha}$ ;
- 求取  $\hat{\mathbf{x}}$ 、 $\hat{\mathbf{y}}$  与  $\alpha$  的交叉协方差  $\mathbf{C}_{x\alpha}$ 、 $\mathbf{C}_{y\alpha}$ ;
- 将  $\hat{\mathbf{x}}$ 、 $\hat{\mathbf{y}}$  各自的误差协方差之逆  $\mathbf{P}_{xx}^{-1}$ 、 $\mathbf{P}_{yy}^{-1}$  进行球状分解, 得到相应球矩阵  $\mathbf{R}_{xx}$  和  $\mathbf{R}_{yy}$ ;
- 求取矩阵  $\mathbf{R}_{xx}^T \mathbf{C}_{x\alpha} \mathbf{P}_{\alpha}^{-1} \mathbf{C}_{\alpha x} \mathbf{R}_{xx}$  和  $\mathbf{R}_{yy}^T \mathbf{C}_{y\alpha} \mathbf{P}_{\alpha}^{-1} \mathbf{C}_{\alpha y} \mathbf{R}_{yy}$  的最大特征值  $\lambda_x$ 、 $\lambda_y$ ;
- 得到交叉相关边界  $S = \sqrt{\lambda_x} \cdot \sqrt{\lambda_y}$ 。

我们注意到,  $\hat{\mathbf{x}}$  ( $\hat{\mathbf{y}}$ ) 的耦合量与  $\sqrt{\lambda_x}$  ( $\sqrt{\lambda_y}$ )、 $\hat{\mathbf{y}}$  ( $\hat{\mathbf{x}}$ ) 是独立的, 故可以在本地计算, 并与  $\hat{\mathbf{x}}$ 、 $\mathbf{P}_{xx}$  ( $\hat{\mathbf{y}}$ 、 $\mathbf{P}_{yy}$ ) 一起传输给融合中心, 以获得交叉相关边界  $S$ 。

### 3.3.3 分散式目标跟踪误差分析案例

#### 1. 状态方程与观测方程

3 个分散部署的代理 (含传感器和融合处理节点) 同时跟踪一个运动目标, 目标状态方程为

$$\mathbf{x}_k = \mathbf{x}_{k-1} + \mathbf{v}_k \quad \mathbf{v}_k \sim N(0, 0.1)$$

每个代理对该目标的观测方程是:

$$\mathbf{z}_{ik} = \mathbf{x}_k + \mathbf{u}_{ik}, \quad \mathbf{u}_{ik} \sim N(0, \sigma_i) \quad \sigma_i = \begin{cases} 3 & i=1 \\ 1 & i=2 \\ 0.1 & i=3 \end{cases}$$

式中, 状态噪声  $\mathbf{v}$  与观测噪声  $\mathbf{u}$  相互独立, 并且对任意  $i \neq j$ ,  $\mathbf{u}_{ik}$  与  $\mathbf{u}_{jk}$  不相关。

#### 2. 融合结构与试验方法

3 个代理按时间间隔周期性进行通信, 传输各自的融合结果。代理 1 与代理 3 通信, 随即代理 3 与代理 2 通信, 再然后代理 2 与代理 1 通信, 每 5 个时间间隔即完成一次循环传输。3 个代理循环发送的融合结构与信息图如图 3.5 所示。




图 3.5 3 个代理循环发送的融合结构与信息图

每个代理采用卡尔曼滤波对自身传感器测量和从其他代理接收的信息进行融合。各代理融合估计信息的相关性产生于：

- 3 个代理观测同一目标（或按相同的状态方程模拟产生同一目标）。
- 从图 3.5 右侧可以看到，每 15 个时间间隔 3 个代理的融合信息在同一时刻汇集到一起，每 10 个时间间隔两个代理的融合信息在同一时刻汇集到一起。由于每个代理的融合输入信息都是对同一目标同一时刻测量信息产生的估计，因此两个以上代理融合信息的汇集体现了对同一目标同一时刻测量信息的重复使用。
- 由于 3 个代理对该目标观测误差不同，因此基于大误差的独立观测信息的融合会产生信息精度相对增益，而基于非独立观测信息的融合会与同一测量信息的重复使用产生相似的相关性和融合误差协方差增长。

该试验采取 5 种估计误差协方差控制方法，主要有：

- ① 使用交叉协方差上、下界的 BCI 方法，其中上界为  $S_1 = \sqrt{\lambda_x} \cdot \sqrt{\lambda_y}$ ，下界  $S_2$  可尝试（训练）选择；
- ② 仅采用交叉协方差上界  $S_1$  的单界 BCI 方法；
- ③ 协方差交集（ $C^2$ ）方法，固定上界  $S_1 = 1$  的 BCI 方法；
- ④ 精度最高的集中式卡尔曼滤波；
- ⑤ 3 个代理各自（无通信）基于自身测量的局部卡尔曼滤波。

### 3. 目标跟踪航迹误差分析

3 个代理采用上述 5 种滤波误差控制方法产生的目标航迹估计误差方差随时间的变化情况如图 3.6 所示。

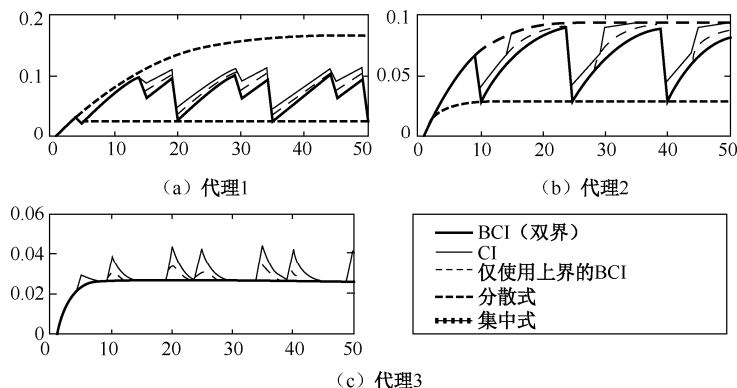


图 3.6 3 个代理采用上述 5 种滤波误差控制方法产生的目标航迹估计误差方差随时间的变化情况



在图 3.6 中,横轴为时间间隔数,纵轴为目标航迹估计误差标准差。对图 3.6 分析如下:

从图 3.6 (a)、(b)、(c) 中的纵坐标曲线可以看出,各代理融合产生的航迹误差与其观测误差对应,代理 1 的误差最大,代理 2 的误差次之,代理 3 的误差最小。

各代理的集中式滤波误差最小,因其采用多个代理相互独立的测量信息,此时每个代理自身信息的重复使用不起主要作用。

各代理的局部分散式滤波误差最大,这是由于仅采用自身观测信息,信息量少且每 15 个时间间隔自身测量重复使用一次,产生融合误差增益。

代理 1 和代理 2 观测误差较大,双界 BCI 方法对分散式滤波有较大的改进,单界 BCI 和 CI 方法产生的航迹误差略大于双界 BCI 方法产生的误差。

代理 1 和代理 2 误差曲线图中,双界 BCI 方法产生的锯齿状误差曲线(单界 BCI 和 CI 方法误差附着在锯齿图上方)的几个底部点是三个代理独立测量信息全部到达的情况,故融合误差较小(与集中式融合相同);锯齿顶端的几个点仅有自身测量信息到来或重复使用自身测量信息,故融合误差较大(与局部分散式融合误差相同);而锯齿的上升/下降段分别反映了到达测量信息的数量和自身观测信息重用状况导致的融合误差增长或降低。

代理 3 属于观测误差较小的情况,此时双界 BCI、集中式、分散式三种融合方法产生的误差相差无几,这是由于观测误差较小时,增加独立观测信息或自身观测信息重复使用以及采取双界 BCI 控制措施等对于改善融合性能已作用不大,因此,它们的误差基本上重合为一条平滑曲线。而单界 BCI 和 CI 方法由于人为扩展了误差协方差,故它们的融合误差略大一些,呈锯齿状分布在该曲线上方。

### 3.4 传感器协同方法

传感器优化协同工作也是分布式信息融合系统设计的一个挑战性问题,通常在地理上分散配置(或机动配置)的探测平台必须在融合计算负荷和网络通信带宽约束下协同运行,才能达到网络系统的全局优化感知效果。考虑一个广阔领域的监视应用,其中各传感器需要采取自组织方式运行,如通过飞机、地面车辆或水面舰艇抛撒大量无源传感器,每个传感器对其所处的局部环境(如自身和邻近传感器位置与状态)的感知以及随机出现的网络的精确连接配置都无法预先确定。一旦确定了传感器及其感知的邻近局部环境,这些传感器在部署后必须具有自组织和间的协同能力。

这里的自组织问题的共同特征是:这些传感器必须在少量工作状态(如采用什么样的感知/休眠策略,哪个相邻传感器向自己传输数据)和作为一个传感器网络的整体效能之间进行有代表性的优化选择。不仅要考虑基于每个传感器状态模式的局部选择,还要考虑相互连接的各传感器状态的联合选择。这样一来,为使传感器网络整体效能极大化,网络连接中的传感器必须协同而不是独自决策。特别是在一个无线传感器网络(WSN)中,由于每个单一传感器都存在资源约束(如有限的功率、通信带宽和计算资源),并且每个传感器仅能与局部邻域中的几个其他节点进行通信(这是由于要尽量使用低功率、小型化天线和装置以及传感器在对抗环境中要降低被发现率等因素所导致的有限传输距离等),因此,协同决策就

更加必要。在分布式信息融合系统中,通常没有中心调度员,此时在网络中配置的节点增加时,为保持解算规模在一个适度的负荷范围内,也要求各传感器节点与其他类型节点之间协同工作。本节给出一个有效的传感器协同方法——极大和算法,该算法能使分散配置的传感器达到一定优化程度协同工作<sup>[10, 11]</sup>。

### 3.4.1 极大和算法模型

用于传感器协同的极大和算法模型与求解原理来源于数学规划。

#### 1. 传感器协同极大和算法效用函数

考虑  $M$  个传感器,每个传感器采用一个离散变量  $x_i (i=1,2,\dots,M)$  来描述其工作状态。采用函数  $U_i(x_i)$  表示  $x_i$  的单一效用。由于每个传感器可能与许多其他传感器进行局部交互,因此一个单一传感器的局部效用  $U_i(X_i)$  既依赖其自身状态  $x_i$ ,又依赖与其交互的其他传感器状态,即依赖于局部状态集合  $X_i (1 \leq i \leq M)$ 。注意各传感器的局部状态集合  $X_i$  之间可能有重叠元素。该网络中传感器协同工作的目标是使各单一传感器局部效用之和达极大:

$$X_i^* = \arg \max \sum_{i=1}^M U_i(X_i) \quad (3.17)$$

式中,  $\sum_{i=1}^M U_i(X_i)$  被称为该传感器网络的全局效用函数,也被称为指标函数。式(3.17)中的选择变量是局部状态集合  $X_i$ ,包括其中每个传感器跟踪哪个目标(传感器指向)、传感器测量精度(信息量)及  $X_i$  中各传感器之间的交互路径(连接关系)和占用带宽等。局部状态集合  $X_i$  的选择直接影响其局部效用  $U_i(X_i)$ ,进而影响全局效用。

之所以能够获得使式(3.17)达极大的最优解  $X^* = (X_1^*, X_2^*, \dots, X_M^*)$ ,是由于每个传感器仅能够与可数的几个邻近代理直接通信,获取有关信息,故每个传感器效能计算的复杂性仅依赖与其通信的邻近代理的状态和数量。因此,如何选择  $X_i$  中  $x_i$  的连接对象,以减少信息重用、少占带宽、效用最大,成为多传感器协同决策必须解决的问题。

#### 2. 极大和算法效用模型

将每个传感器  $S_i$  分解为一个变量节点  $x_i$  和一个效用节点  $U_i$ ,如图3.7给出的一个三传感器网络示例。其中  $x_i$  表示单一传感器  $S_i$  的状态变量,效用  $U_i$  表示传感器  $S_i$  的局部状态集合  $X_i$  产生的局部效用,它来源于  $x_i$  自身效用和与其交互的各邻近节点信息产生的对  $x_i$  的效用增量。




图 3.7 三传感器网络示例

这里的传感器效用(单一效用、局部效用和全局效用)采用目标信息量或与其成正比的

目标估计精度。效用节点对与其连接的各变量节点的输入信息与自身节点信息（自身的新探测信息和上一周期先验估计信息）进行融合产生该节点的局部效用。

式（3.17）就是一个传感器网络的极大和效用模型。对于如图 3.7 所示的三传感器网络，从其中的三个传感器观测覆盖和交互状态可以看出，该传感器网络的全局效用函数是：

$$U = U_1(x_1, x_2) + U_2(x_1, x_2, x_3) + U_3(x_2, x_3)$$

式中， $U_1(x_1, x_2)$ 、 $U_2(x_1, x_2, x_3)$ 、 $U_3(x_2, x_3)$  分别表示三个传感器的局部效用函数。

当传感器之间存在探测覆盖区域时，相应传感器对出现在覆盖区内的目标独立进行探测，此时集中融合会导致该目标信息效用（精度或信息量）的增加，但多测量信息传输与计算会增加系统负荷，并且当对同一目标的两个独立观测信息误差较小时，并不会显著增加信息效用。此时如果观测信息不独立，还会产生与信息重复使用类似的负面效果，这样一来，在覆盖区域内的两个或两个以上探测信息的选择（即其传输路径设置）就成为影响系统效用的重要因素之一。由此不难看出，在传感器之间存在探测覆盖区域时，极大和算法难以获得最优解。当传感器之间不存在探测覆盖区域时，探测信息交互已无必要，因为不存在两个或两个以上传感器对同一目标的测量，此时各传感器的单一效用之和就等于全局效用。局部最优状态之和就是全局最优，极大和算法自然能收敛到最优解。

### 3.4.2 极大和算法约束条件与模型求解

传感器协同极大和算法模型通常采用离散求解的方法。

#### 1. 约束条件

第一个约束条件是变量节点信息无损约束。流经变量节点的信息无损约束条件是指从变量节点  $x_i$  流出并进入效用节点  $U_j$  的信息等于所有邻近  $x_i$  的其他效用节点（即非  $U_j$  节点）流入变量节点  $x_i$  的信息之和：

$$q_{i \rightarrow j}(x_i) = \alpha_{ij} + \sum_{k \in M_i \setminus j} r_{k \rightarrow i}(x_i) \quad (3.18)$$

式中， $q_{i \rightarrow j}(x_i)$  为从  $x_i$  流入  $U_j$  的观测或融合信息， $r_{k \rightarrow i}(x_i)$  为从效用节点  $U_k$  流入变量节点  $x_i$  的信息（指产生效用  $U_k$  所依赖的观测或融合信息）； $M_i \setminus j$  为连接到  $x_i$  的其他效用节点（除去  $U_j$ ）下标集合； $\alpha_{ij}$  是规格化参数，以防止循环连接状态出现信息无限增长。

第二个约束条件是节点局部效用最大约束。节点局部效用最大约束条件是指从效用节点  $U_j$  流出并进入变量节点  $x_i$  的效用信息等于所有邻近  $U_j$  的其他变量节点  $x_k$ （即非  $x_i$  节点）流入  $U_j$  的信息产生的效用与  $U_j$  自身效用之和的极大值：

$$r_{j \rightarrow i}(x_i) = \max_{k \in N_j \setminus i}^{x_k} [U_j(x_i) + \sum_{k \in N_j \setminus i} q_{k \rightarrow j}(x_k)] \quad (3.19)$$

式中， $r_{j \rightarrow i}$  表示从  $U_j$  流入  $x_i$  的信息， $q_{k \rightarrow j}$  为如（3.18）所定义的从变量节点  $x_k$  流入效用节点  $U_j$  的信息； $N_j \setminus i$  为连接到效用节点  $U_j$  的其他（非  $x_i$ ）变量节点下标集合； $v_j(x_i) + \sum_{k \in N_j \setminus i} q_{k \rightarrow j}(x_k)$  是指  $N_j \setminus i$  中各变量节点的一个状态向量与状态变量  $x_i$  融合产生的局部效用；而  $\max_{k \in N_j \setminus i}^{x_k}$  是指历经  $N_j \setminus i$  中各变量节点状态对  $x_i$  变量的局部效用增益之和的极大值。

## 2. 约束条件举例说明

对于如图 3.7 所示的三传感器网络，式 (3.18) 的具体形式描述如下：

从图 3.7 (b), (c) 所示的交互状态和两因素节点连接状态，可知

$$M_1 = \{1, 2\}, \quad M_2 = \{1, 2, 3\}, \quad M_3 = \{2, 3\}$$

于是  $M_{1/2} = \{1\}$ ,  $q_{1 \rightarrow 2}(x_1) = \alpha_{12} + r_{1 \rightarrow 1}(x_1)$ ，如图 3.8 (a) 所示；

$M_{2/1} = \{2, 3\}$ ,  $q_{2 \rightarrow 1}(x_2) = \alpha_{21} + r_{3 \rightarrow 2}(x_2) + r_{2 \rightarrow 2}(x_2)$ ，如图 3.8 (b) 所示；

$M_{2/3} = \{1, 2\}$ ,  $q_{2 \rightarrow 3}(x_2) = \alpha_{23} + r_{1 \rightarrow 2}(x_2) + r_{2 \rightarrow 2}(x_2)$ ，如图 3.8 (c) 所示；

$M_{3/2} = \{3\}$ ,  $q_{3 \rightarrow 2}(x_3) = \alpha_{32} + r_{3 \rightarrow 3}(x_3)$ ，如图 3.8 (d) 所示。

由于  $M_{1/3}$  与  $M_{3/1}$  是空集，故

$$q_{1 \rightarrow 3}(x_1) = \alpha_{13}, \quad q_{3 \rightarrow 1}(x_3) = \alpha_{31}$$

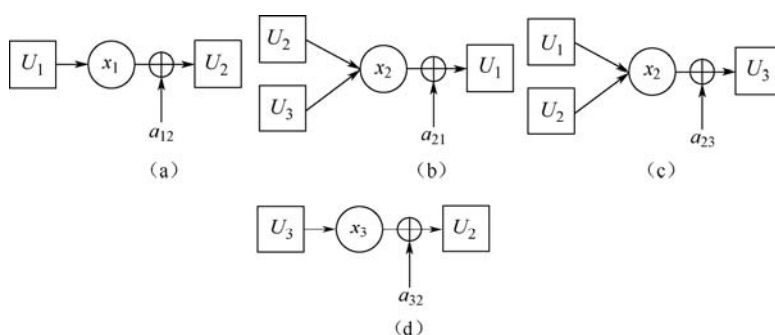


图 3.8 三传感器网络的信息无损约束

对于如图 3.7 所示的三传感器网络，式 (3.19) 的具体形式描述如下：

注意  $N_{1/2} = \{1\}$ ,  $r_{1 \rightarrow 2}(x_2) = \max_{x_1} [U_1(x_1) + q_{1 \rightarrow 1}(x_1)]$ ，如图 3.9 (a) 所示；

$N_{2/1} = \{2, 3\}$ ,  $r_{2 \rightarrow 1}(x_1) = \max_{x_2, x_3} [U_2(x_2) + q_{3 \rightarrow 2}(x_3) + q_{2 \rightarrow 2}(x_2)]$ ，如图 3.9 (b) 所示；

$N_{2/3} = \{1, 2\}$ ,  $r_{2 \rightarrow 3}(x_3) = \max_{x_1, x_2} [U_2(x_2) + q_{1 \rightarrow 2}(x_1) + q_{2 \rightarrow 2}(x_2)]$ ，如图 3.9 (c) 所示；

$N_{3/2} = \{3\}$ ,  $r_{3 \rightarrow 2}(x_2) = \max_{x_3} [U_3(x_3) + q_{3 \rightarrow 3}(x_3)]$ ，如图 3.9 (d) 所示。

由于  $N_{1/3}$  与  $N_{3/1}$  是空集，故

$$r_{1 \rightarrow 3}(x_3) = \max_{x_1} U_1(x_1), \quad r_{3 \rightarrow 1}(x_1) = \max_{x_3} U_3(x_3)$$

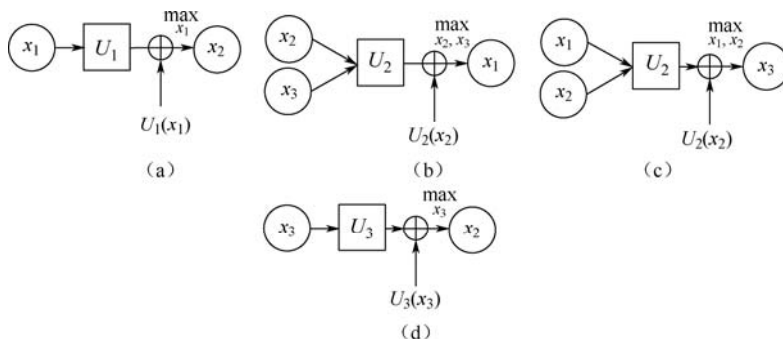


图 3.9 三传感器网络节点局部效用最大约束

### 3. 极大和算法模型求解方法

基于上述两个约束条件的传感器协同极大和算法模型的求解方法通常是直接对图 3.7 (c) 表示的因素交互连接图进行运算, 通常采用离散方式分别求取各网络节点的局部最佳工作状态 (包括连接路径、传感器指向即跟踪对象、资源消耗和信息效用等), 通过确定由式 (3.18) 和 (3.19) 表示的从变量节点到效用节点以及从效用节点到变量节点应传递的信息来实现。即通过确定物理背景下的传感器探测覆盖状况、目标是否来自覆盖区, 覆盖区内目标的各传感器测量是否独立以及可能的通信带宽和信息效用确定与一个代理互通的邻域代理节点集合  $M_i$  和  $N_j$ , 通过使式 (3.19) 所示的所有  $x_i$  节点局部效用  $U_i(x_i)$  之和 (即式 (3.17) 表示的全局最优效用) 达极大来求取传感器网络各节点的全局最佳状态  $x_i^*$  ( $i=1, 2, \dots, M$ )。

确定传感器网络各节点局部最佳状态可以采用序贯过程, 即按式 (3.18) 和式 (3.19) 随着自身和邻近区域节点新的目标观测和融合信息的到来, 不断获取和改进各代理的局部最佳状态。该算法对之前信息可随机初始化, 然后通过一个传感器接收来自自身或邻近传感器的新消息予以更新, 不存在严格排序或同步问题。

从图 3.7 (c) 的两因素连接图和式 (3.18) 可以看出, 流入和流出变量节点的信息是一个单一变量节点的函数, 从式 (3.19) 可以看出, 该函数表示网络所提供的该变量节点信息效用与其邻近节点流入信息产生的效用增益的总和。因此, 在这些信息在网络中传播的任一时刻, 本算法能使代理  $i$  通过使其自身效用与邻近节点代理对其提供的效用增益之和达极大来确定局部最佳状态  $X_i^*$ , 这需要在本地计算流入代理  $i$  的所有邻近节点 (包括自身) 的效用函数  $z_i(X_i)$  :

$$z_i(X_i) = \sum_{j \in M_i} r_{j \rightarrow i}(x_k) \quad (3.20)$$

从而得到

$$X_i^* = \arg \max_{x_i} z_i(X_i) \quad (3.21)$$

这里的  $X_i^*$  仅表示网络中各节点代理的全局 (联合) 最优状态在某一时刻的边缘最优状态, 故基于式 (3.20) 和式 (3.21) 能够得到各传感器状态的局部最佳连续更新估计。

不难看出, 在传感器探测存在覆盖区域 (即因素连接图存在循环) 时, 传感器协同工作的极大和效用模型求解算法不能保证算法收敛, 即使收敛也不能保证得到全局最优解。问题主要出现在某一传感器对位于覆盖区域中的目标探测信息可能分发给多个其他节点, 或覆盖区中目标的多传感器探测信息非统计独立等情况, 此时会出现与某些节点交换信息的邻域相互重叠或一个测量信息重复计入等情况, 此时求解式 (3.17) 的各种方法都无法获得全局最佳状态, 并且会产生过大的信息处理负荷和通信带宽需求。

然而, 对大量平台协同问题的许多经验性评估表明, 除了值得注意的低计算量和通信代价外, 这里描述的极大和算法实际上能比其他近似算法产生更高质量的解。

最后需要指出的是, 如果观测或融合信息连续到来并连续更新各传感器状态, 那么极大和算法可应用于动态问题中, 其中代理之间的交互状态及从这些交互中获得的效用可能会随时间变化。例如, 在多传感器多目标跟踪系统中, 该算法可用来控制跟踪不同目标不同传感

器的工作状态,此时每个传感器的效用由于目标位置的改变及其他传感器状态的变化而连续变化,这使得每个代理在动态跟踪中能够保持对传感器状态的连续更新估计,使网络感知系统动态获得全局最优效用。

### 3.4.3 基于极大和算法的多传感器协同跟踪案例

这里给出采用极大和算法的三传感器多目标协同跟踪案例,跟踪场景如图 3.10 所示。




图 3.10 三传感器多目标协同跟踪场景

该跟踪场景中包含了 3 个固定设置的传感器,每个传感器具有有限的观测区域 (ROO),如图中虚圆域界定的范围所示。图中有 3 个运动目标,初始位置如相应标识 (A,B,C) 旁的圆圈位置,每个目标从初始位置出发沿图中所示的直线运动。从该场景不难看出,各传感器对目标的人为探测初始分配应是:传感器 1 跟踪目标 B,传感器 2 跟踪目标 C,传感器 3 跟踪目标 A。每个目标在运动过程中超出上述界定的传感器 ROO 时,要进行相应的传感器对跟踪目标的探测交接。

为了验证本节描述的多传感器协同的极大和算法的正确性和优势,在该案例中采用了 3 种传感器探测状态控制策略,以产生的目标航迹的总信息量为效用函数来比较各种控制策略的优劣。3 种传感器的状态控制策略是:

- 局部策略:每个传感器节点仅采用自身传感器的局部观测定位和跟踪目标,通过使航迹总信息达极大来选择自身传感器控制参数(指向参数,即跟踪哪个目标);
- 集中策略:每个传感器节点对 3 个传感器的所有观测进行融合,采用使所有目标航迹信息量达极大的可能组合选择各传感器控制参数;
- 分布式策略:人为确定传感器初始跟踪目标(传感器初始探测指向),然后采用本节给出的极大和算法获取使目标运动过程中效能达极大的各传感器最优控制参数。

不难看出,由于这里选择和传感器的指向参数就是指选择传感器跟踪的目标,因此在传感器初始跟踪目标确定后,只出现在目标位于两个或两个以上传感器探测覆盖区中,且进行目标探测交接选择的时候,控制传感器指向参数才发生变化(跟踪目标的改变)。

下面基于实验结果给出如图 3.11 所示的 3 种传感器控制策略(局部、集中、分布式)

的性能比较,对3种策略下的目标跟踪性能进行分析。

图 3.11 横轴为仿真实验时间间隔数,纵轴为3个传感器跟踪的目标航迹总信息量。比较图 3.11 中3种控制策略的性能曲线可以看出:

- 基于极大和算法的分布式传感器控制策略与集中式策略在性能上几乎相同,这是由于分布式策略人为确定每个传感器的初始跟踪目标,并且极大和算法能够对传感器指向参数进行全局优化控制,使目标探测交接时避免采用重复观测,实现无冗余交接,因此性能与集中式策略产生的最优性能接近,而分布式策略相比集中式策略的优势在于大大减少了信息传输负荷与融合计算量。




图 3.11 局部、集中和分布式传感器控制策略性能比较

- 局部策略在性能上低于集中式和分布式策略,主要体现在目标处于探测覆盖区域时(18~48间隔中)产生的性能降低,因为此时目标可能被多个传感器独立观测到,而局部策略仅采用自身观测信息,其性能(信息量)较集中式下降。特别在28和40时间间隔前后,两目标可能出现在航线交叉点(目标B与目标C,目标A与目标B)附近,这时可能产生关联错误,使局部策略无法解决两传感器同时选择同一目标的冲突情况,漏掉了正确关联航迹点,因此会产生目标航迹信息量的减少,使局部策略性能降低。

此外,基于极大和算法的传感器参数控制性能还依赖于探测交接容许时间,即当目标运动进入两传感器探测覆盖区,即将超出原分配传感器的 ROO 而进入另一个传感器 ROO 时,原传感器要向另一传感器进行该目标的探测交接,包括该目标原有航迹信息的交接和传感器控制参数改变等,因此需要一定的信息交接时间。图 3.12 以集中式控制策略产生的最优性能为对照,考虑随目标探测交接时间(即磋商时间)在 50~1 000 ms 之间调整的情况下分布式极大和算法的性能所出现的变化(对每个磋商时间,仿真实验 20 次)。

从图 3.10 可以看到,目标 B 通过场景中心附近时,传感器 1 要向传感器 3 交接;目标 A 超出传感器 3 的 ROO 时,传感器 3 要向传感器 2 交接;目标 C 超出传感器 2 的 ROO 时,传感器 2 要向传感器 1 交接。图 3.12 展示了这 3 种目标探测交接态势下分布式极大和算法

性能随不同交接容许时间的变化情况。




图 3.12 3 种目标探测交接态势下分布式极大和算法随不同交接容许时间的变化情况

从图 3.12 可以得出如下结论：

交接磋商时间越长，目标航迹信息越完整（不至于丢点），信息重复使用率越低（无冗余），最终分布式策略的性能收敛于集中式策略。

## 3.5 自利平台的优化协调方法

### 3.5.1 概念与背景

前面一节已表明了各传感器代理的局部效用与传感器网络的全局效用相结合的传感器最佳协同运行控制，通过极大和算法能达到或近似达到这一点。该问题可以建模为合作的多代理系统（MAS）。在本节中，我们考虑网络连接的不同平台如何响应每个传感器，包括接收每个传感器的探测信息并向其他平台传播，以获得该传感器网络的全局最大信息效用。例如，在抢险救灾中，每个政府和非政府组织必须共享传感器（传感器组或各类信息源）收集的信息，以帮助协调各类有效的救援行动。此时，各传感器工作在一个竞争而不是合作的环境中，各个代理（救援组织）都力图获得自身最大利益（指救援效果）而展开信息（以及救援设施和手段）的争夺。此时面临的挑战性问题就是：基于多代理系统的开放性，各自利代理如何进行信息交互和协调，以从开放性中获取系统的最佳效用<sup>[12,13]</sup>。

本节描述的计算机制设计是提供一个原则性框架，采用该框架能使设计的系统展现出全局性质，而不是只顾及各平台的自利行动和目的。由于该挑战性问题的核心是信息竞争问题，其目的是获得最大的信息增益，因此该机制设计还会带来经济方面的竞争性问题，它是由信息传输、计算等设备成本产生的（如代理有限的计算能力、不计成本和无差错的信息传输及



网络的有限开放性和动态性约束等)。这样一来问题就归结为设计各代理和全系统的评价指标,通过交换各代理的指标,协调系统的资源分配(网络带宽占用、信息资源占用等),寻求各代理自身效用和系统全局效用极大化。在我们的传感器网络场景中,信息量(或信息精度)就是一个原则上的通货或评价指标,在传感器处理和交换不精确观测的任何问题中都可以应用这一指标,因为感知信息最终将以产品或服务的形式出现,因此信息质量和效用指标具有实际经济价值。

### 3.5.2 目标跟踪中的多代理协调问题

考虑一个场景,其中采用多传感器检测目标。每个传感器具有一个局部的、不精确的监视区域,需要与其他传感器互通信息以提高其观测的精确性。这样,该传感器网络观测实际上就是目标经过这些传感器监视区域形成的一张视图。由于传感器之间信息交互受限于网络带宽,因此如何最优分配有限的带宽,需要进行全局决策,以达到传感器网络的全局感知效果——形成一张精确的、满足应用需求的现实视图。

在该场景中,每个传感器都考虑两个区域,一个是传感器能够达到的目标观测区域(Region Of Observe, ROO),另一个是传感器希望监视的关注区域(Region Of Interest, ROI)。图 3.13 描绘了一个典型的传感器网络目标跟踪场景,其中给出了传感器 1 的 ROI 和 6 个传感器的 ROO。




图 3.13 传感器网络目标跟踪场景

从图 3.13 中可以看到一个目标落入传感器 1、传感器 3 和传感器 5 的 ROO 覆盖区域中。由于测量中的固有噪声,代理 1 (传感器 1) 对该目标的观测带有一定不确定性(例如目标位置、速度、型号等,通过一个概率分布来描述其噪声即不确定性),并可通过获得来自代理 3 和代理 5 对该目标的观测信息,经过信息融合来降低这个不确定性。然而,如果代理 1 由于带宽限制仅能接收一个其他代理的观测,那么它就必须判断应该获取哪个代理的观测才能最大程度降低该不确定性。如果代理 3 和代理 5 也进行类似判断,那么这些判断结果很可能产生冲突。显然,不同的观测数据流向(哪个传感器传输观测数据,沿哪条路径传输即传输给哪个代理)对于减少全局不确定性来说(或等价的信息量增加及信

息精度增高)将达到不同的效果。这样一来,这里的多传感器目标跟踪平台优化协调问题的高层次描述就是:在通信网络带宽约束下分配信息流,使所有传感器对其 ROI 中的关注目标信息总增益达最大。

将该问题作为一个 MAS 问题,其中将每个传感器视为一个代理集合  $I$  中的一个代理  $i$ ,它包括数据(测量数据或融合数据)和表征该数据精度(或等价的信息量)的一个变量  $x_i$ 。该数据变量有一定尺度,从而有一个传输带宽需求  $bw_i$ 。考虑最简单的通信协议来展现带宽约束,使任一传感器能够同时对所有其他传感器进行(消息)发送。系统传输数据可以使用的总带宽仅是这些传感器能够实际传输其数据带宽需求的一个子集。

表征该 MAS 问题的两个假设是:

- 数据分发计算和代理之间通信传输所占时间小于其他目标出现(接收所占)时间,即计算和传输不影响其他目标的观测和接收,这是对该建模机制框架的时间要求;
- 网络中各代理均具有关于该传感器网络拓扑结构及其邻近节点的理想、共用知识(各传感器的位置、性能、状态及网络连接状况等)。这就消除了通信系统(特别是 WSN)中邻近节点的发现问题。

这两个假设使我们的 MAS 框架设计可以只集中于带宽约束下的数据流分配问题。下面我们给出每个代理基于数据精度  $x_i$  的度量所产生的接收数据评价函数。

### 3.5.3 目标跟踪 MAS 模型的效用评价函数

本节给出基于卡尔曼滤波形式的目标跟踪 MAS 模型的效用评价函数(又称效用指标函数)。传感器网络中各代理对目标具有相同的观测方程:

$$z(t) = H(t)y(t) + n(t) \quad (3.22)$$

式中,  $y(t)$  是系统在时刻  $t$  的状态,  $H(t)$  是线性观测模型,  $n(t)$  是零均值随机变量,服从方差  $R(t)$  的高斯分布。我们知道,一个代理基于  $N$  个观测(来自自身传感器观测或从其他代理接收的观测)的卡尔曼滤波的目标状态估计协方差之逆(即 Fisher 信息量或信息精度)的更新方程是:

$$P^{-1}(t|t) = P^{-1}(t|t-1) + \sum_{j=1}^N H^T(j)R^{-1}(j)H(j) \quad (3.23)$$

式中  $P^{-1}(t|t)$  就是基于  $N$  个观测滤波获得的目标状态估计精度,其中右端第一项是目标在  $t$  时刻的状态预测精度,第二项的右端求和部分表示对  $t$  时刻的  $N$  个观测进行融合获得的信息增益,即目标状态估计精度增益。在我们的问题中,接收来自其他代理的观测数据的价值(效用)即可通过从这些其他代理的观测中得到的信息增益来表示。

为了达成有效信息路径分配,需在融合之前计算来自每个测量  $z(t)$  的信息增益,这样,我们就能够将代理  $i$  基于其邻近代理  $j$  的  $t$  时刻测量  $z(t)$  产生的目标估计精度增益  $x_j$  表示为

$$x_j = H^T(j)R^{-1}(j)H(j) \quad (3.24)$$

当邻近的所有其他代理都将其观测传输给代理  $i$  时,通过融合获得的信息增益为

$$v_i = x_i + \sum_{j \in I \setminus i} x_j \quad (3.25)$$

式中,  $x_i$  是代理  $i$  自身在  $t$  时刻的测量产生的信息增益,  $I$  是可能为代理  $i$  提供观测信息的邻近代理下标集,  $I \setminus i$  是指除掉  $i$  本身。式 (3.24) 和式 (3.25) 称为该 MAS 系统中代理  $i$  基于其所能接收的观测信息产生的局部效用函数 (又称评价函数)。

考虑本节第二个假设给出的网络连接状态, 即各代理之间的可能数据流和可达概率, 代理  $i$  的局部效用函数可改写为

$$v_i(x, f) = x_i + \sum_{j \in I \setminus i} f_{ij} \alpha_{ij} x_j \quad (3.26)$$

其中,

$$f_{ij} = \begin{cases} 1 & \text{代理 } i \text{ 和代理 } j \text{ 之间有信息传输} \\ 0 & \text{代理 } i \text{ 和代理 } j \text{ 之间无信息传输} \end{cases}$$

$\alpha_{ij}$  为代理  $i$  和代理  $j$  之间的信息可达概率。

在目标跟踪 MAS 模型中, 式 (3.26) 表示的局部效用评价函数具有如下两个性质:

$$\frac{\partial v_i(x, f)}{\partial x_j} \geq 0 \quad i, j \in I, i \neq j \quad (3.27)$$

$$\frac{\partial v_i(x, f)}{\partial x_i} > \frac{\partial v_j(x, f)}{\partial x_i} \quad i, j \in I, i \neq j \quad (3.28)$$

其中, 式 (3.27) 表示其他代理  $j$  只能为代理  $i$  带来正增益, 即其他代理提供的观测或融合信息只会提高而不是降低代理  $i$  的信息精度 (增加信息量); 式 (3.28) 表示代理  $i$  的观测信息 (或融合信息) 对其效用函数的影响大于其他代理信息的影响, 也就是说在选择某代理传感器跟踪的目标时, 本代理能够获得所跟踪目标的最大信息精度或信息量; 从式 (3.28) 可以引伸出代理  $i$  的 ROI 必须限制在其 ROO 之内, 即同一代理的 ROI 和 ROO 满足:

$$\text{ROI} \subseteq \text{ROO} \quad (3.29)$$

否则, 出现在代理  $i$  的 ROO 外、ROI 内的目标只能依赖其他代理的传感器观测产生信息效用, 即其他代理对该目标观测信息对代理  $i$  效用的影响大于代理  $i$  自身观测信息的影响, 这与式 (3.28) 的性质相矛盾; 从式 (3.28) 还可以引伸出另一个性质, 即各代理之间相互覆盖的 ROO 必须满足:

$$\sum_{j \in I \setminus i} \alpha_{ij} < 1 \quad (3.30)$$

此式表示代理  $i$  的 ROO 不能被其他代理的 ROO 完全覆盖, 否则代理  $i$  将是多余的, 即其 ROI 中目标信息效用可完全从其他代理的观测中获得, 这显然与式 (3.28) 相矛盾。

### 3.5.4 考虑信道衰减的信息多级最优传输路径

由于信号在传输过程中会产生信道衰减和出现传输错误, 因此一个代理所提供的观测或融合信息在网络中最多只能对有限传输级别的各节点产生信息效用。

首先我们考虑一个代理提供入网信息的一级传输路径问题。设  $F$  表示一级信息传输可能的路径集合,  $f \in F$ ,  $f$  是如式 (3.26) 中定义的传输路径  $f_{ij}$ ,  $I$  是可能为该代理提供信息的邻近代理下标集。于是从式 (3.26) 可知, 该代理的效用函数依赖于分配的一级传输路径  $f$  及该路径所连接的各代理 (包括该代理自身) 提供信息产生的信息增益。首先, 将一个代

理按一级路径  $f$  将其信息传送给相应各邻近节点产生的信息效用增益表示为  $\sum_{i \in I} v_i(f, x)$ ，则一个代理的一级最优传输路径可通过使该信息获得极大效用来获得：

$$f^* = \arg \max_{f \in F} \left[ \sum_{i \in I} v_i(f, x) \right] \quad (3.31)$$

第二，确定基于信道衰减的信息可能传输级数，即一个代理的入网信息可能惠及的最多代理节点。设传输级别为  $l(l=0, 1, \dots, m-1)$ ， $m$  为待求的信息最多可能传输的级数，在第  $m$  传输级别上，由于信道衰减，某级代理节点接收的入网信息对其信息效用已不产生影响，即可视其接收的  $x_i$  信息不存在， $m$  的求解如下：

$$m = \arg \left\{ \max_{f_m \in F_m} \left[ \sum_{j \in I_m} v_j(f_m, x_m) \right] = \max_{f_m \in F_m} \left[ \sum_{j \in I_m \setminus i} v_j(f_m, x_m) \right] \right\} \quad (3.32)$$

式中， $F_m$  是第  $m$  级可能传输路径组合的集合， $f_m$  是其中一个路径组合， $I_m$  是  $f_m$  连接的第  $m$  级邻近节点的下标集合。

代理入网信号的递级传播如图3.14所示。




图 3.14 代理入网信号的递级传播

图中各可能传输级别对应的信息传输路径组合分别为  $f_0, f_1, \dots, f_{m-1}$ 。我们在这里将  $m$  取式 (3.32) 确定的  $m$  的最小值，即首次出现式 (3.32) 花括号中等式成立的情况对应的  $m$  值。

最后，与式 (3.31) 同理，可获得代理  $i$  入网信息  $x_i$  的各可能传输级别上的最优传输路径为

$$f_l^* = \arg \max_{f_l \in F_l} \left[ \sum_{i \in I_l} v_i(f_l, x_i^l) \right] \quad l=1, \dots, m-1 \quad (3.33)$$

值得注意的是，式 (3.33) 所确定的各级别最优路径仅是每级局部最优路径，并不是多级全局联合最优路径，或者说只是多级路径联合分布的各边缘分布。

### 3.5.5 基于拍卖机制的网络带宽优化分配

网络连接的多自利平台协同探测 MAS 系统的带宽分配可以采用拍卖机制。在该机制中，传感器测量信号占支配地位。该机制要求各传感器将探测信息交给拍卖中心，拍卖中心基于

信息效用（价值）和可能流向（传输路径）对各相关代理（传感器节点和信息处理节点）分配有限的信息传输带宽，以使各传感器测量信息和各相关代理的融合信息得到最大的系统开放信息增益。每个传感器或融合代理在向拍卖中心提供信息时，既有局部自利考量（如适当增大自身信息传输量，使拍卖中心折扣分配给其他传感器或代理的传输带宽），又应该具有全局利他考量（即适当折扣自身信息传输量，使拍卖中心尽量确保分配给其他代理的传输带宽）。基于拍卖机制的网络带宽分配的最终目标是是网络的全局信息效能达极大，并使各单一代理的计算耗费降低，我们研究其中一个子类，即策略验证或激励兼容策略<sup>[17]</sup>，其步骤为：

① 每个代理  $i$  将其所有可能采用的信息流向（传输路径） $f \in F$  占用带宽及可能产生的效用函数  $v_i(f, x)$  传送给拍卖中心， $f \in F$  含有各级可能传递路径组合；

② 每个代理  $i$  向拍卖中心传送其入网信息状态即其效用  $x_i$ ；

③ 拍卖中心基于信道衰减，按式（3.32）计算入网信息可惠及的最多传输级别  $m$ ；

④ 拍卖中心按式（3.33）逐级求取信息  $x_i$  的局部最优传输路径  $f^* = \{f_0^*, f_1^*, \dots, f_{m-1}^*\}$ 。

为求取基于拍卖机制的代理信息动态最优传输路径，需要建立逐级效用或增益模型和动态优化模型，步骤如下：

① 在相邻上下游最优传输路径中不损失信息效用的约束下，寻求在路径上至少要传输的信息量  $z_i^l$ ：

$$z_i^l = \inf \{y_i : \sum_{i \in I_{l-1}} v_i(f_{l-1}, y_i, x_{-i}^{l-1}) = \sum_{i \in I_l} v_i(f_l, y_i, x_{-i}^l)\} \quad l=1, \dots, m-1 \quad (3.34)$$

式中  $x_{-i}^l = \{x_j\}_{j \in I_l \setminus i}$ 。

② 计算代理  $i$  的收益。该收益是代理  $i$  将其入网信息  $x_i$  提供给其他代理所获得的，应由  $x_i$  沿逐级最优路径传输直至衰减到无效用影响之前的各级别接收代理来支付。第  $l$  级（ $l=0, 1, \dots, m-1$ ）代理的支付为

$$\sum_{j \in I_{l-1} \setminus i} v_i(f_{l-1}, z_i^{l-1}, x_{-i}^{l-1})c_j - \sum_{j \in I_l \setminus i} v_j(f_l, z_i^l, x_{-i}^l)c_j \quad (3.35)$$

式中， $c_j$  是节点  $j$  信息的单位效用价值。该式第一项是第  $l-1$  级最优路径  $f_{l-1}^*$  所连接的所有其他代理从代理  $i$  提供的信息  $z_i^{l-1}$  获得的效用价值增益之和，第二项是各  $l-1$  级代理沿最优路径  $f_{l-1}^*$  向连接的  $l$  级各代理传送的信息  $z_i^l$  所产生的效用价值增益之和；二者之差就是  $l-1$  级代理应向代理  $i$  支付的效用代价。于是，代理  $i$  提供的入网信息  $x_i$  应获得的总收益是：

$$\gamma_i = \sum_{l=0}^{m-1} \left[ \sum_{j \in I_{l-1} \setminus i} v_i(f_{l-1}, z_i^{l-1}, x_{-i}^{l-1})c_j - \sum_{j \in I_l \setminus i} v_j(f_l, z_i^l, x_{-i}^l)c_j \right] \quad (3.36)$$

式（3.36）就是一个代理  $i$  提交一批入网信息  $x_i$  所获得的总效用收益，又称正支付。代理  $i$  接收其他代理某个传输级别的入网信息获得信息增益所应付出的代价（负支付）按式（3.35）计算。

③ 求取代理  $i$  入网信息的多级最优传输路径。

从式（3.36）不难看出，基于拍卖机制一个代理  $i$  提供一批入网信息的多级最优传输路径  $f^* = \{f_0^*, f_1^*, \dots, f_{m-1}^*\}$ ，应通过使式（3.36）所示的入网信息  $x_i$  总收益达极大获得：

$$f^* = \arg \max_{f_0, f_1, \dots, f_{m-1} \in F} \sum_{l=1}^m \left[ \sum_{j \in I_l \setminus i} v_i(f_{l-1}, z_i^{l-1}, x_{-i}^{l-1}) c_j - \sum_{j \in I_l \setminus i} v_i(f_l, z_i^l, x_{-i}^l) c_j \right] \quad (3.37)$$

如果该拍卖机制不考虑支付代价, 仅考虑信息  $x_i$  可能惠及各级传输节点的效用增益, 则式 (3.37) 成为

$$f^* = \arg \max_{f_0, f_1, \dots, f_{m-1} \in F} \sum_{l=1}^m \left[ \sum_{j \in I_l \setminus i} v_j(f_{l-1}, z_i^{l-1}, x_{-i}^{l-1}) \right] \quad (3.38)$$

值得指出的是, 式 (3.37) 或式 (3.38) 是对多级传输路径的综合寻优, 或者说是寻求多级最优传输路径的联合分布, 是一个多级动态优化过程, 而式 (3.33) 基于单一级别效用确定的各传输级别的最优路径  $f_l^*$  ( $l=0, 1, \dots, m-1$ ) 仅是综合最优路径向量  $f^* = \{f_0^*, f_1^*, \dots, f_{m-1}^*\}$  各分量联合分布的边缘分布。当原始入网信息  $x_i$  在传输过程中对某一传输级别上不同代理效用 (或收益) 的影响具有较大差别时, 会产生不同级别传输路径的较强相关性, 并且式 (3.33) 并没考虑相邻级别最优路径  $f_{l-1}^*$  与  $f_l^*$  之间的相互衔接。因此, 必须考虑式 (3.37) 或 (3.38) 所示的多级动态优化过程, 可以采用基于马尔可夫过程的动态规划等方法对其进行求解。当各级别传输路径无关或仅具有较弱的相关性时, 式 (3.33) 仍不失为一种可选方法, 它可以获得近似最优解, 且算法简单。

#### ④ 多代理入网信息的综合优化传输路径问题。

通常, 多平台网络各节点产生的探测信息或融合信息是逐一入网 (逐一拍卖) 的, 因此当入网信息时间间隔较大时, 按式 (3.37) 或式 (3.38) 求取一个入网信息的多级动态优化传输路径是可行的, 但要付出较大的运算代价, 随着信息到来间隔的减少, 信息传输路径之间的耦合性增强, 甚至出现路径冲突, 无法逐一计算序贯到来信息的最优传输路径。当各平台传感器 ROO 相互覆盖时, 多个平台提供信息的关联性增加, 此时如 3.5.2 节所述, 会使邻近节点传输路径的冲突现象加剧。因此必须考虑网络连接所有平台的输入信息可能同时到来的综合优化路径分配问题。

若网络中的节点代理数为  $s$ , 则这  $s$  个代理的探测或融合信息同时入网传输的综合优化传输路径  $F^*$  可以通过使各代理的总收益 (如式 (3.36) 所示) 之和达极大或使各代理的总效用 (如式 (3.38) 右端所示) 之和达极大来获得:

$$F^* = \arg \max_F \sum_{t=1}^s \left\{ \sum_{l=1}^m \left[ \sum_{j \in I_l \setminus i} v_i(f_{l-1}^t, z_i^{l-1}, x_{-i}^{l-1}) c_j - \sum_{j \in I_l \setminus i} v_i(f_l^t, z_i^l, x_{-i}^l) c_j \right] \right\} \quad (3.39)$$

或

$$F^* = \arg \max_F \sum_{t=1}^s \left\{ \sum_{l=1}^m \left[ \sum_{j \in I_l \setminus i} v_j(f_{l-1}^t, z_i^{l-1}, x_{-i}^{l-1}) \right] \right\} \quad (3.40)$$

式中,  $F = \{f^1, f^2, \dots, f^s\}$  为  $s$  个代理信息的传输路径, 其中  $f^k = \{f_0^k, f_1^k, \dots, f_{m-1}^k\}$  为代理  $k$  信息的  $m_k$  级传输路径,  $k=1, 2, \dots, s$ 。

式 (3.39) 或式 (3.40) 所示的求取多代理信息的综合优化传输路径公式的带宽分配约束是针对同时进行传输的信息路径而言的, 即通过对同时传输的多代理信息进行可能的动态带宽分配确定各代理信息的最优传输路径。视同时入网的各代理信息的相同级别传输是同步

进行的，则仅针对每个传输级别上的多代理信息传输路径施以带宽约束：

$$\sum_{k=1}^s \sum_{j \in I_{ik} \setminus i} f_{ijk}^l \alpha_{ijk}^l z_{ik}^l bw_{ik}^l \leq bw \quad l=0,1,\dots,m_{\max} \quad (3.41)$$

式中， $f_{ijk}^l$  为代理  $k$  的节点  $i$  入网信息  $z_{ik}^l$  在  $l$  级别上向邻域节点  $j$  的传输路径， $\alpha_{ijk}^l$  表示相应可达性， $bw_{ik}^l$  为传输  $z_{ik}^l$  所需带宽， $bw$  为全网总带宽， $m_{\max} = \max_{1 \leq k \leq s} \{m_k\}$ 。

### 3.5.6 仿真案例

该仿真案例将本节建立的网络带宽对各平台代理的优化分配模型，即在网络带宽约束下使各平台代理信息效用（或收益）总和达极大的最优传输路径规划模型，应用到一个多传感器多目标跟踪的仿真数据融合问题中。该仿真案例跟踪产生各代理入网信息最优传输路径并观察其传输分发的整个信息拍卖过程，以验证本节建立的基于信息拍卖过程的优化传输路径模型，如图 3.15 所示。

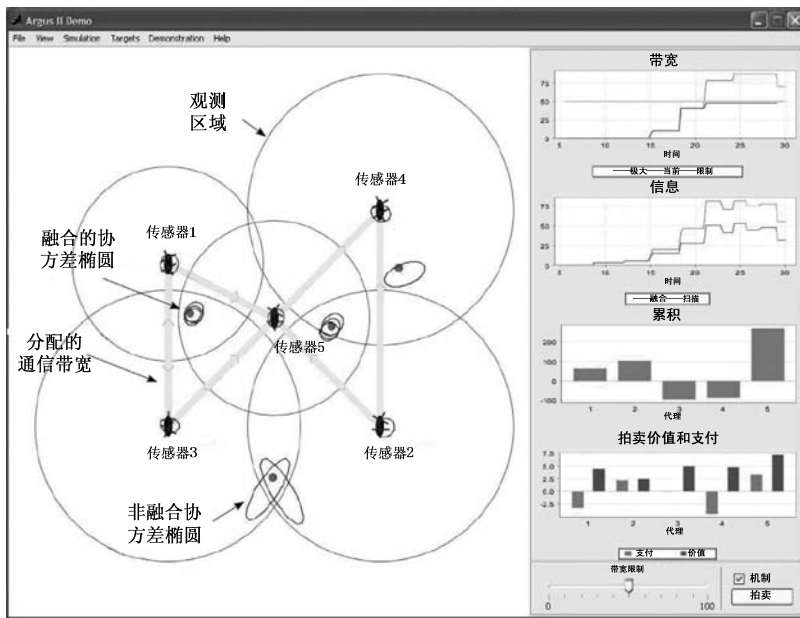


图 3.15 基于信息拍卖过程的优化传输路径模型

图 3.15 左侧展现了固定配置的 5 个传感器位置及其 ROO、各传感器对几个目标的观测情况以及观测信息的融合和非融合误差椭圆，以体现融合增益；还以粗虚线连接表示出了各传感器之间的传输带宽分配情况。图 3.15 右边各直方图描述信息和带宽拍卖过程中网络的总带宽占用和使用情况（其随时间变化）、各传感器总的观测信息积累和融合信息积累（随时间变化）情况以及各代理的基于拍卖机制产生的效用和支付及积累情况，具体说明如下：

从图 3.15 左侧可以看出，一个目标落入传感器 2 和传感器 3 的 ROO 中，另一个目标落入传感器 1、传感器 3 和传感器 5 的 ROO 中，还有一个目标落入传感器 2 和传感器 5 的 ROO 中。对于这些传感器探测覆盖区中的目标信息来说，粗虚线分配的带宽并不充分，因此需要进行基于拍卖机制的信息传输路径分配。

图 3.15 右侧上方第一个阶梯曲线图表示在该拍卖机制中, 该网络系统占用的通信带宽随时间增加的状况以及容许使用的最大和最小带宽约束区间。

图 3.15 右侧上方第二个阶梯曲线图表示在该拍卖过程中, 网络系统所有代理获得的观测回波信息量(信息精度)和融合信息量(信息精度)随时间的变化情况, 可以看出这两个效用函数指标都随时间而增加, 并且融合指标(精度)在超过一定时间(20 s)后始终高于原始扫描回波指标。

图 3.15 右侧底部直方图表示在该拍卖机制产生的传输路径之下每个代理(传感器)所具有的支付和产生的效用, 其中传感器 1 和传感器 4 具有负支付, 这是由于它们从其他代理接收的信息多于它们向其他代理传输的信息。传感器 5 效用最高, 这是由于其获得的(自身探测和从其他代理获取的)目标信息最多(来自 3 个传感器对 3 个目标的 6 批观测信息)。

图 3.15 右侧中部直方图表示各代理的效用(信息增益)积累, 其中传感器 1、传感器 2 和传感器 5 采用本节给出的拍卖机制, 产生的效用极大化积累始终是正值, 而传感器 3 和传感器 4 没有采用本节给出的优化带宽分配机制, 或者由于故障、长远考虑或蓄意行为, 无法传输自身信息, 因此无法达到效用(信息精度)最大, 反而使所积累的效用逐渐消耗, 直到产生负效用(效用或信息精度低于需求阈值)。需要指出的是, 在一个合作的环境中, 必须鼓励各代理真实报告自身获得的信息, 而不是出于自利目的而藏匿信息。系统要能够识别出具有负效用或低效用代理, 并将其从网络中除掉, 才能基于传输真实的观测和融合信息实现有限网络带宽的合理分配, 实现网络的全局信息增益极大化的目标。

## 3.6 合作对象信用估计

在一个合作的 MAS 和开放式分布式系统中, 一个代理必须有代表性地选择合作对象以达成预期合作目标, 包括代理自身目标和 MAS 的全局目标。一个代理选择合作对象的准则除了应用业务需求外, 还必须考虑合作对象履行其合作承诺(完成合作协议或合同)的可靠性。因此, 需要建立一个信用(Trust)模型, 使代理能够从中获得下述功能:

- 能够估计一个合作对象即信息提供者的可信赖性(即信用), 以使代理能够从合作对象及时获取正确的直观经验;
- 能够使一个代理获得对合作对象信用估计的不确定性表示;
- 能够将该信用估计及其不确定性作为信誉(Reputation)报告与其他代理进行交换;
- 对接收的其他代理信誉报告进行滤波并与自身获得的直观经验进行融合, 达成更精确的合作对象信用估计<sup>[14,15]</sup>。

本节开发一个计算合作对象信用的随机模型, 该模型使代理能够组合异类、相关、多维声誉报告, 并与其他代理进行交换, 特别是考虑一个代理力图获得一揽子服务(如声音、视频、数据等服务)合同, 并且其他代理的直观经验很可能也来自各类服务的不同组合, 这是由于各代理的服务可能会使用共享资源或信息基础设施, 这些共享因素的质量限制了各代理成功提供服务的状态。



### 3.6.1 合同的期望效用与协方差的概念

考虑一个代理力图从一个单一提供者获得一揽子服务,为了进行理性合作决策或商议获取这一揽子服务的费用,该代理必须估计与该提供者商定合同的期望效用,该期望效用模型涉及的物理量如下:

① 合同的输出向量  $\mathbf{X}$ 。由于这一揽子服务中并不是每个服务都能成功递交,故  $\mathbf{X}$  表示该合同中各项服务的状态向量,如  $\mathbf{X}=[o_a=1, o_b=0, o_c=1, \dots]^T$  表示合同中的服务  $a$  和服务  $c$  成功递交,而服务  $b$  未成功递交。

② 合同效用向量  $\mathbf{U}(\mathbf{X})$ 。 $\mathbf{U}(\mathbf{X})$  表示合同中每项服务都成功交付产生的效用,这是合同规定的各项服务要达到的效用指标向量,即

$$\mathbf{U}(\mathbf{X})=[u(o_a=1), u(o_b=1), u(o_c=1), \dots]^T$$

式中,  $u(o_a=1)$  表示合同规定的服务  $a$  要达到的边缘效用指标,该效用指标的达成程度,即其期望值依赖于服务  $a$  成功递交的概率  $p(o_a=1)$ 。

③  $\hat{\mathbf{p}}(\mathbf{X})=[\hat{p}(o_a=1), \hat{p}(o_b=1), \hat{p}(o_c=1), \dots]^T$  表示合同中各项服务成功递交的概率估计向量。

④  $\mathbf{V}(\mathbf{X})=\begin{pmatrix} V_a & C_{ab} & C_{ac} & \dots \\ C_{ab} & V_b & C_{bc} & \dots \\ C_{ac} & C_{bc} & V_c & \dots \\ \vdots & \vdots & \vdots & \ddots \end{pmatrix}$  是概率估计向量  $\hat{\mathbf{p}}(\mathbf{X})$  的估计误差协方差矩阵,其中对

角元素  $V_a$  表示  $\hat{p}(o_a=1)$  对应的服务  $a$  成功递交概率估计的方差,其表示  $\hat{p}(o_a=1)$  的不确定性;而各非对角元素表示两个不同服务成功递交概率估计的误差协方差,即这两个不同服务成递交的相关性,如  $C_{ab}$  表示  $\hat{p}(o_a=1)$  与  $\hat{p}(o_b=1)$  之间的相关性。

于是我们得到合同的效用估计,即期望效用为

$$E\{E[\mathbf{U}]\}=\hat{\mathbf{p}}(\mathbf{X})^T \mathbf{U}(\mathbf{X}) \quad (3.42)$$

效用估计的协方差为

$$\text{var}\{E[\mathbf{U}]\}=\mathbf{U}(\mathbf{X})^T \mathbf{V}(\mathbf{X}) \mathbf{U}(\mathbf{X}) \quad (3.43)$$

### 3.6.2 基于独立贝塔分布的合同信用估计

从合同效用向量  $\mathbf{U}(\mathbf{X})$  的定义可知其是合同规定的各项服务要达到的指标向量,因此按式 (3.42) 和式 (3.43) 估计合同期望效用及其协方差就归结为估计合同中各项服务成功递交的概率向量  $\mathbf{p}(\mathbf{X})$  及其协方差  $\mathbf{V}(\mathbf{X})$ ,称为合同的信用估计。

若已知效用向量  $\mathbf{U}(\mathbf{X})$  的概率分布,一个代理就可以将之前的合同完成情况(即合同中各项服务交付状态)视为合同效用观测,基于观测统计量计算各服务成功递交概率估计向量  $\hat{\mathbf{p}}(\mathbf{X})$  及其协方差估计量  $\mathbf{V}(\mathbf{X})$ 。对于含有多个同类服务的合同,该计算容易实现。例如  $\mathbf{U}(\mathbf{X})$  通常服从下述狄利克雷分布:

$$p(p_1, p_2, \dots, p_k / \alpha_1, \alpha_2, \dots, \alpha_k) = \frac{\sum_{i=1}^k \Gamma(\alpha_i)}{\Gamma(\sum_{i=1}^k \alpha_i)} \cdot \sum_{i=1}^k p_i^{\alpha_i-1}$$

上式是多项分布函数的共轭先验分布,从之前合同中各项服务成功交付次数容易计算估计量  $\hat{\boldsymbol{p}}(\boldsymbol{X}) = (\hat{p}_1, \hat{p}_2, \dots)$  和  $\boldsymbol{V}(\boldsymbol{X})$ 。

对于含有多个异类服务合同,需要建立更复杂的信用估计模型。当合同中各服务(同类或异类)之间相关时,可以采用 3.3 节给出有界协方差增长(BCI)方法,将相关服务转化为独立服务进行误差协方差增量控制。此时,对转化后的两个独立服务采用独立贝塔分布建立合同信用模型,通过对每项服务的交付状态估计,计算  $\hat{\boldsymbol{p}}(\boldsymbol{X})$  和  $\boldsymbol{V}(\boldsymbol{X})$ 。

设一个代理具有  $N$  个之前的合同输出的直观统计结果,其中服务  $a$  成功交付  $n_a$  次,再加上本次成功交付,共成功交付  $p = n_a + 1$  次,未成功交付次数为  $q = N - n_a + 1$  次。按照贝塔分布,服务  $a$  成功交付的均值和方差分别为

$$\begin{aligned}\hat{p}(o_a = 1) &= \frac{p}{p+q} = \frac{n_a+1}{N+2} \\ V_a &= \frac{pq}{(p+q)^2(p+q+1)} = \frac{(n_a+1)(N-n_a+1)}{(N+2)^2(N+3)}\end{aligned}\quad (3.44)$$

同样可以基于之前的合同服务输出观测结果,计算服务  $b$  成功交付的均值和方差为

$$\begin{aligned}\hat{p}(o_b = 1) &= \frac{p}{p+q} = \frac{n_b+1}{N+2} \\ V_b &= \frac{(n_b+1)(N-n_b+1)}{(N+2)^2(N+3)}\end{aligned}\quad (3.45)$$

提供服务  $a$  和服务  $b$  的合同信用就是对这两个服务成功递交的均值和方差进行融合产生的,该合同成功交付状态  $\boldsymbol{X} = [o_a = 1, o_b = 1]^T$  的概率估计向量  $\hat{\boldsymbol{p}}(\boldsymbol{X})$  及其协方差  $\hat{\boldsymbol{V}}(\boldsymbol{X})$ 。通过对式(3.44)和式(3.45)采用凸组合融合,在高斯分布下得到该合同成功交付概率估计向量及其协方差为

$$\begin{cases} \hat{\boldsymbol{p}}(o_a = 1, o_b = 1) = \boldsymbol{V}_b(\boldsymbol{V}_a + \boldsymbol{V}_b)^{-1} \hat{\boldsymbol{p}}(o_a = 1) + \boldsymbol{V}_a(\boldsymbol{V}_a + \boldsymbol{V}_b)^{-1} \hat{\boldsymbol{p}}(o_b = 1) \\ \boldsymbol{V}(o_a = 1, o_b = 1) = \begin{bmatrix} \boldsymbol{V}_a & \mathbf{0} \\ \mathbf{0} & \boldsymbol{V}_b \end{bmatrix} \end{cases}$$

由于未考虑两服务的相关性,不必计算  $\boldsymbol{V}(o_a = 1, o_b = 1)$  中的非对角元素,视其为零。

如果采用去除相关性的 BCI 方法的协方差交集(CI)融合公式,取  $\omega = 0.5$ ,两相关性服务成功交付概率协方差矩阵为

$$\boldsymbol{V}(\boldsymbol{X}) = \begin{pmatrix} 2\boldsymbol{V}_a & \mathbf{0} \\ \mathbf{0} & 2\boldsymbol{V}_b \end{pmatrix}$$

这里的协方差矩阵对角元素增长系数是维度 2,目的是确保协方差矩阵的相对保守性。

### 3.6.3 基于卡尔曼滤波的异类服务合同信用估计

#### 1. 异类服务合同信用估计公式

采用卡尔曼滤波进行异类服务合同信用估计是基于合同中每项服务都成功递交的先验概率  $\hat{\boldsymbol{p}}_{\text{先验}}(\boldsymbol{X})$  及其误差协方差  $\hat{\boldsymbol{V}}_{\text{先验}}(\boldsymbol{X})$  (是从之前的直观经验获得或来自上一周期的估计),

在获得之后的观测  $\mathbf{O}$  及其协方差  $\mathbf{R}$  (来自其他代理的信誉报告) 之后, 采用下述卡尔曼滤波进行融合, 获得该异类服务合同的后验概率估计及其协方差:

$$\begin{aligned}\hat{\mathbf{p}}_{\text{后验}}(\mathbf{X}) &= \hat{\mathbf{p}}_{\text{先验}}(\mathbf{X}) + K[\mathbf{O} - \hat{\mathbf{p}}_{\text{先验}}(\mathbf{X})] \\ \mathbf{V}_{\text{后验}}(\mathbf{X}) &= (\mathbf{I} - K)\mathbf{V}_{\text{先验}}(\mathbf{X})\end{aligned}\quad (3.46)$$

式中,  $K = \mathbf{V}_{\text{先验}}(\mathbf{X})[\mathbf{V}_{\text{先验}}(\mathbf{X}) + \mathbf{R}]^{-1}$  是卡尔曼滤波增益。式 (3.46) 就是基于卡尔曼滤波的异类服务合同信用估计模型。

然而, 对于异类服务合同来说, 往往会出现来自其他代理的信息报告 (观测) 不完整的情况, 即缺少某个维度的服务递交信息。此时, 通常采用将该观测误差协方差矩阵  $\mathbf{R}$  中相应的服务维度方差设为无穷大来表示。我们知道, 含有无穷大元素的矩阵运算存在困难, 故我们在这里采用估计误差的 Fisher 信息矩阵 (即信息精度) 表示的卡尔曼滤波形式。

设  $\mathbf{Y} = \mathbf{V}(\mathbf{X})^{-1}$  表示随机向量  $\mathbf{X}$  的估计精度协方差矩阵, 于是  $\mathbf{X}$  的估计精度  $\hat{\mathbf{y}}$  是估计精度协方差与其递交状态估计之积:

$$\hat{\mathbf{y}} = \mathbf{V}(\mathbf{X})^{-1} \hat{\mathbf{p}}(\mathbf{X}) \quad (3.47)$$

此时通过将  $\mathbf{V}(\mathbf{X})^{-1}$  中相应缺失的服务维度元素方差设置为零, 即可采用信息矩阵形式的卡尔曼滤波对该异类服务合同信用估计的先验精度与来自其他代理的信誉报告 (即观测) 的估计精度进行融合, 以得到该异类服务合同信用的后验估计精度及其协方差矩阵:

$$\begin{aligned}\hat{\mathbf{y}}_{\text{后验}} &= \hat{\mathbf{y}}_{\text{先验}} + \hat{\mathbf{y}}_0 \\ \mathbf{Y}_{\text{后验}} &= \mathbf{Y}_{\text{先验}} + \mathbf{Y}_0\end{aligned}\quad (3.48)$$

式中,  $\hat{\mathbf{y}}_0 = \mathbf{R}^{-1}\mathbf{O}$  为其他代理提供的观测中的合同信用估计精度,  $\mathbf{Y}_0 = \mathbf{R}^{-1}$  为估计精度协方差。式 (3.48) 可序贯进行, 以基于陆续到来的信誉报告 (观测) 实现合同信用估计精度的积累。式 (3.48) 所示的卡尔曼滤波形式在 MAS 中特别有用, 因其能够将来自多代理的信誉报告 (观测) 以任何次序简单地增加到一个代理的先验估计中。

## 2. 合同信用的先验估计

一个合同信用的先验概率估计  $\hat{\mathbf{p}}_{\text{先验}}(\mathbf{X})$  及其协方差  $\mathbf{V}_{\text{先验}}(\mathbf{X})$  可以从一个代理之前的合同完成状态输出, 采用前面的狄利克莱分布统计计算出来, 其中  $\hat{\mathbf{p}}_{\text{先验}}(\mathbf{X})$  和  $\mathbf{V}_{\text{先验}}(\mathbf{X})$  中的对角元素可基于合同输出数据计算, 如两个服务合同情况按式 (3.44) 和式 (3.45) 计算, 而  $\mathbf{V}_{\text{先验}}(\mathbf{X})$  中的非对角元素则需要狄利克莱分布的详细知识, 特别是合同中各服务的相关性知识, 才能计算出来<sup>[14]</sup>。当一个代理的之前合同输出数据中缺少某些服务递交状况数据时, 可采用与上一小节同样的处理方法, 将协方差矩阵  $\mathbf{V}(\mathbf{X})$  中的相应元素设置为无穷大或将合同信用估计精度矩阵  $\mathbf{Y} = \mathbf{V}(\mathbf{X})^{-1}$  相应元素设置为零的卡尔曼滤波方法。

由于基于卡尔曼滤波的合同信用估计公式 (3.46) 是对先验估计与观测 (来自其他代理的信誉报告) 进行融合, 这就涉及对合同信用观测  $\mathbf{O}$  及其协方差矩阵  $\mathbf{R}$  的计算问题, 其中观测  $\mathbf{O}$  来源于代理对合同中各服务的当前递交状态的统计结果, 易于计算; 而观测协方差矩阵  $\mathbf{R}$  的计算比较困难, 因为  $\mathbf{R}$  描述观测  $\mathbf{O}$  随信用概率  $p(\mathbf{X})$  的变化情况, 但  $p(\mathbf{X})$  是未知的, 正是我们所要估计的。

若采用具有狄利克莱分布的卡尔曼滤波求取观测协方差矩阵  $\mathbf{R}$ , 可以利用卡尔曼滤波的灵活性, 先找到一个保守的矩阵  $\mathbf{R}^*$  代替  $\mathbf{R}$ , 如采用 BCI 方法确定一个保守的  $\mathbf{R}^*$ , 就能够保证我们获得的估计与真实的观测协方差矩阵是一致的。

### 3.6.4 合同信用模型仿真验证案例

为了验证本节建立的合同信用计算模型的有效性, 我们给出一个仿真案例。

#### 1. 仿真剧本

该信用模型仿真验证系统中包含 10 个代理, 每个代理将产生于自身经验 (是由含有两个服务的一个提供者给出的) 的合同信用先验估计与从其他 9 个代理接收的信誉报告 (观测) 进行融合, 每个代理都力图评估这个合同提供者的信用, 以计算与其他代理交互的期望效用, 为其优化合作决策提供依据。

#### 2. 仿真过程

共进行 1 000 次仿真试验, 过程如下:

① 每次试验中, 合同的输出采用两相关服务的一个任意联合分布模拟产生, 每次试验产生 400 个合同输出结果, 并将它们随机分配给每个代理;

② 某些代理可获得 (即观测到) 两个服务, 其他代理只获得一个服务;

③ 每个代理将自身接收的观测产生的先验估计与接收的其他 9 个代理的信用报告, 采用本节给出的两种方法 (基于独立贝塔分布的信用估计和基于卡尔曼滤波的信用估计) 进行融合计算, 分别获得合同的后验信用估计;

④ 基于 1 000 次仿真试验对这两种方法的统计性能进行比较, 采用下述两个信用估计度量指标:

- 合同信用估计的信息量 (信息精度) 度量指标, 采用协方差矩阵之逆的行列式形式:  

$$I = \det[\mathbf{V}(\mathbf{X})^{-1}]$$
, 它是度量估计误差协方差矩阵综合不确定性的一个标准方法<sup>[16]</sup>, 10 个代理的期望信息量为

$$E[I] = E\{\det[\hat{\mathbf{V}}(\mathbf{X})^{-1}]\}$$

- 合同信用估计的规格化误差

$$E = [\hat{\mathbf{p}}(\mathbf{X}) - \mathbf{p}(\mathbf{X})]^T \mathbf{V}(\mathbf{X})^{-1} [\hat{\mathbf{p}}(\mathbf{X}) - \mathbf{p}(\mathbf{X})]$$

规格化误差通常被称为规格化标准误差 (NSE), 也被称为偏差系数, 用来描述估计分布与真实分布的偏离程度。我们知道, NSE 通常服从  $\chi^2$  分布, 这里 NSE 与真实分布的偏差是指其与  $\chi^2$  分布基数 (维度) 之差。在本次仿真实验中, 验证提供两个服务的合同信用估计模型, 因此基数为 2。

#### 3. 仿真结果

图 3.16 给出基于独立贝塔分布和卡尔曼滤波的信用估计结果和采用上述两个度量指标的比较。图中, 横轴为合同输出数, 即各代理每次试验获得的观测数, 在 0~400 变化; 图 3.16 (a) 纵轴表示合同信用估计的期望信息量, 从中可以看出基于卡尔曼滤波的信用估计信

息量（信息精度）大大超过独立贝塔分布（典型情况是按 3 倍因子增加）。图 3.16（b）纵轴表示规格化标准误差（NSE）。从中可以看出，对于该案例的两个服务相关程度未知的情况，基于卡尔曼滤波信用估计的 NSE 比独立贝塔分布信用估计更靠近真实  $\chi^2$  分布，随观测数增加卡尔曼滤波信用估计逐渐靠近  $\chi^2$  分布基数 2；而独立贝塔分布没有这个变化趋势，很难收敛到  $\chi^2$  分布基数 2，并且二者的距离随观测数增加而加大。

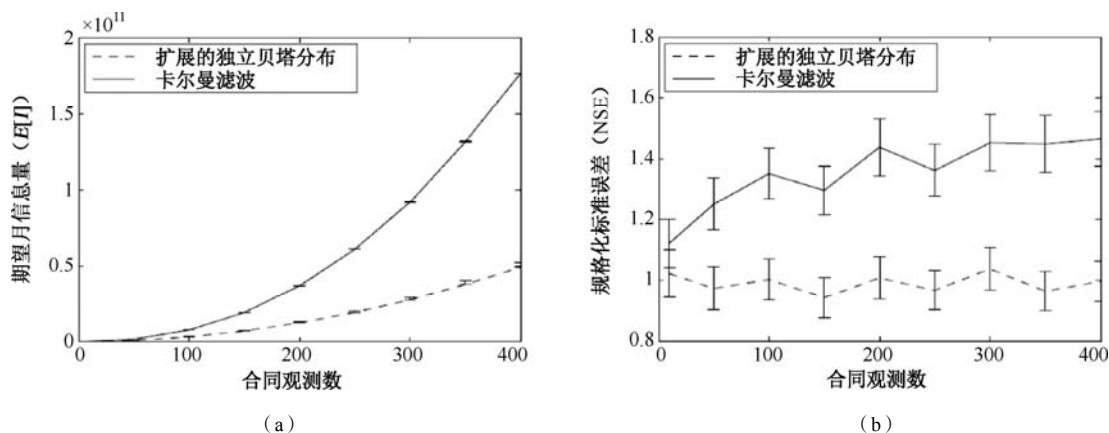


图 3.16 两种信用估计结果和采用上述两个度量指标的比较

表 3.1 给出了一个代理基于这两种信用估计所得到的期望效用及其标准差，是采用式 (3.42) 和式 (3.43) 进行统计计算获得的，其中服务  $a$  和服务  $b$  成功交付数分别为  $n(o_a = 1) = 2$  和  $n(o_b = 1) = 6$ 。

表 3.1 一个代理基于两种信用估计所得到的期望效用及其标准差

方 法	$E\{E[U]\} \pm \sqrt{\text{VAR}(E[U])}$
真实分布	$5.80 \pm 0.27$
扩展的独立贝塔分布	$5.86 \pm 0.53$
卡尔曼滤波	$5.82 \pm 0.34$

由表 3.1 可以看出：当两种信用估计方法产生的期望效用都接近真实分布时，卡尔曼滤波更精确的信用估计误差协方差矩阵能产生一个更好的期望效用的标准差估计  $5.82 \pm 0.34$ ，与真实分布  $5.80 \pm 0.27$  在均值和标准差上都相差无几；而采用 BCI 产生的独立贝塔分布产生的效用估计  $5.86 \pm 0.53$  则与真实分布相差较大。

## 3.7 基于人—代理集合体（HAC）的分布式信息融合

### 3.7.1 问题的提出

随着电子技术日新月异地发展，低廉的传感器和计算设备在我们周围与日俱增，为我们应用计算机的工作方式带来了深刻的变化。与向单一计算机发指令的被动方式相比，人们越来越多地愿意与高度互联的计算部件（代理）合伙工作，以实现自动和智能行为。这种工作方式使人能够与软代理连续灵活地建立一个与其他对象的一系列合作关系，形成人—代理集

合体 (Human—Agent Collectives, HAC), 以达到各自的和整体的目标。

另一方面, 正在出现的第三代信息融合旨在建立一个“人在其中的信息融合系统”<sup>[18]</sup>, 这是当前高级信息融合学界从复兴信息融合学科思想的角度出发<sup>[19]</sup>, 在一定程度上摒弃“信息融合自动化”思想, 迈向与应用领域紧密结合的研究方向提出的, 以在信息融合系统生命周期各阶段、各环节、各级别上, 发挥人的参与和主导作用, 充分满足用户要求, 并驱动信息融合学科的发展。第三代信息融合模型是在美国国防部实验室联合理事会 (JDL) 的第二代信息融合模型基础上发展起来的 (见文献[18]1.1 节), 其特征是实现两个耦合, 即信息融合与人紧密耦合, 以及信息融合与应用紧密耦合, 以提升融合产品的性能和应用效能, 其典型代表是用户—融合模型<sup>[20-22]</sup>。

以网络为依托的信息系统的实质是为人的业务应用提供信息平台或辅助工具, 因此只有采用“人在其中”的模式, 即用户参与和主导系统的立项设计、运行和应用, 才能实现最高性价比和最大效用。支持网络中心战的分布式信息融合系统的主要目标是为网络中心战的各级各类作战应用节点提供情报支撑。如果视单一节点 (或网络连接的多节点) 的自动计算和信息处理为代理, 而将各级战场情报 (态势) 分析和作战指挥视为用户, 则当前出现的人—代理集合体 (HAC) 技术模式是非常适宜的, 它能够在一定程度上达成网络中心战需求, 又存在技术上的可行性, 也符合信息融合技术的发展方向。

### 3.7.2 人—代理集合体 (HAC) 中的用户精炼

用户对信息融合 HAC 的精炼主要是指融合系统设计阶段和运行应用中要充分考虑人对各种融合级别能够采取的调整和控制措施, 以实现各融合级别和整个系统的功能改进和效能提升。

#### 1. 人在融合精炼中的作用

文献[23]第 2.1 节描述了 JDL2004 顶层模型, 如图 3.17 所示。

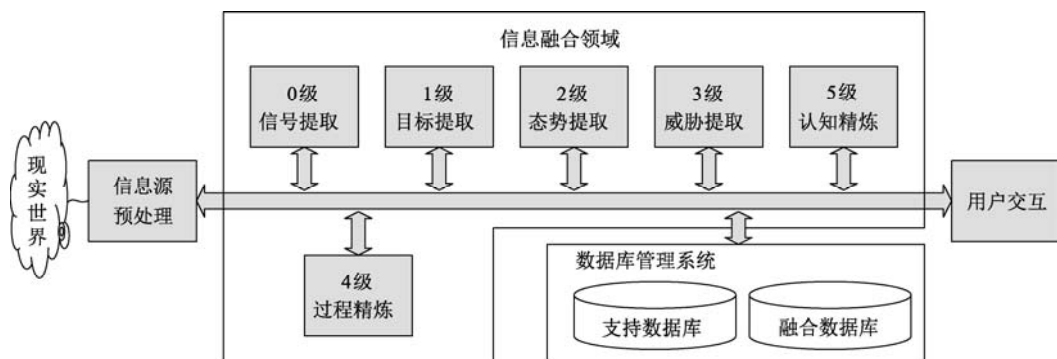


图 3.17 JDL2004 顶层模型

该模型是 Steinberg<sup>[24]</sup>与 Hall 等人<sup>[25]</sup>2004 推荐模型的综合, 它首次提出了第 5 级信息融合: 认知精炼的概念, 旨在改进融合系统与一个或多个用户/分析员之间的交互能力。该功能能够对界面的用户可视性 (可理解性), 界面内容及其与用户认知的一致性、错误补偿能

力、与用户的协同能力、群体决策和对进一步的态势与威胁分析提供支持。不难看出，该模型中的“认知精炼”主要是指人的认知对融合系统的功能改进，是通过把用户与设计者相结合实现的。

文献[20-22]建立的用户—融合模型是为了突出用户对融合系统功能改进的作用，将第5级信息融合改为“用户精炼”，如图3.18所示。

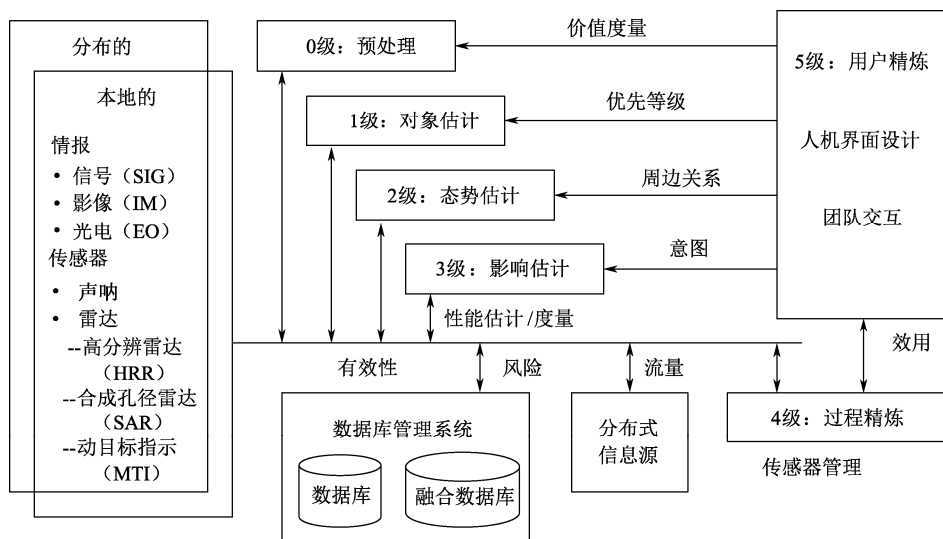


图 3.18 用户—融合模型

该模型描述“用户精炼”对各融合级别的支撑关系：

- 向 0 级融合提供数据价值度量基准，以使系统优先收集和处理价值较高的数据，摒弃低价值数据，提升对后续融合级别的支持能力，降低系统负荷；
- 向 1 级融合提供对象处理优先级，即用户基于任务需求确定对象（目标）重要程度，以使系统优先处理重要对象数据，提升对任务的支持度；
- 向 2 级融合提供周边关系（Contextual）信息，这是态势估计不可或缺的，以支持实体内外关系估计并进一步完善属性识别，生成适时、准确的战场态势；
- 向 3 级融合提供意图信息，向系统提供指挥员或情报人员分析的对手意图，修改自动估计的不足或错误，生成及时、准确的威胁判断结果，支持后续的作战决策和行动；
- 向 4 级融合提供效用需求信息，基于任务需求与系统产生的诸级融合结果的差距，确定每一融合级别的动态规划效用需求指标，为融合过程精炼控制提供支撑。

## 2. 用户精炼功能与方法

在图 3.18 中，为达成用户精炼对其他融合级别的支撑作用，作为 5 级融合的用户精炼要具有下述三项功能：

① 对 0~4 级融合的支撑和调整。用户精炼要实现上面新确定的对 0~4 级融合的支撑功能，还要按任务要求，基于测量数据和实时变化的态势，确定和调整 0~4 级融合采用的模型和数据。如目标状态和测量模型、状态和属性估计方法，指挥员关注态势和威胁估计模

型和求解方法等。

② 判定（决策）的正确性度量基准和方法。确定判定准则，判定度量指标与计算模型，以及判定评估方法等，如态势变化判定准则、威胁判定度量指标等，涉及信息的非完整性和不确定性。

③ 基于任务需求的高级推理。对于融合系统无法实现或自动推理结果与用户需求相差甚远的推理，必须借助 HAC 的交互协作方式进行，如基于征候（不完整）信息的目标意图估计、威胁估计或重点关注目标的属性识别等推理，以及伪装隐蔽和欺骗识别推理等。

图 3.19 给出了 5 级融合：用户精炼（User Refinement, UR）的主要功能和应用实现方法。

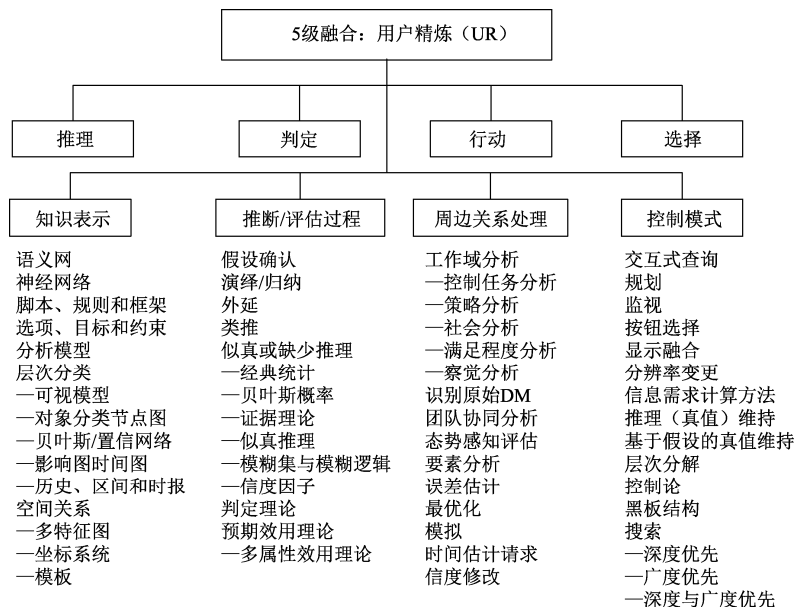


图 3.19 5 级融合：用户精炼（UR）的主要功能和应用实现方法

图 3.19 中，选择框是指用户给出融合系统面对的应用任务，用来确定融合系统的期望需求，任务调整会导致融合需求变化；行动框是指用户对态势的响应活动，包括对行动方案（COA），如探测方案和作战方案的预先、主动的实时规划或调整；推理框是指用户向系统提供推理知识或以交互方式推理，提高推理满足任务需求的程度；判定框是指用户或工程师将判定准则和命题假设注入到推理算法中，判定度量参数可预先设置或交互调整。图 3.19 最下面 4 列内容是融合系统与人可能采用的模型、技术和方法。

### 3. HAC 中的用户精炼活动

#### （1）态势感知活动

态势感知（Situation Awareness, SAW）是人对客观存在的认知活动，美国心理学家 Endsley 认为态势感知是对一个时空范围内环境元素的察觉、对其含义的理解和对未来状态的预测<sup>[26-29]</sup>，它给出的经典态势感知模型如图 3.20 所示。

图 3.20 既给出了以人为主导的三级态势感知活动，又描述了态势感知所支持的应用活动，包括决策和实施活动所涉及的设计目标、信息处理机制等，这些都取决于人的能力、经



验和训练水平。

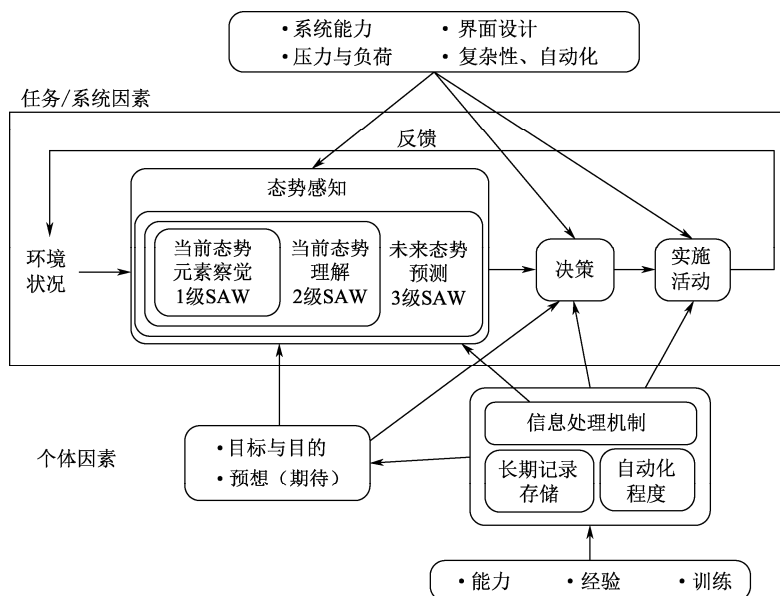


图 3.20 Endsley 态势感知模型

Endsley 态势感知模型与信息融合顶层结构在目标、功能和应用上特别贴近，使其成为信息融合 JDL 顶层模型的先导（详见文献[30]第 1 章）。5 级信息融合用户精炼集中体现了人对各感知级别（0~4 级）的精炼活动。而图 3.20 给出的态势感知模型对于信息融合与人的业务应用紧密耦合起到了引领作用。

## （2）知识转换活动

知识转换活动是指信息形成（提取）知识的处理过程，以及将人的知识转换为计算设备理解信息的过程。通常采用两种途径实现：自顶向下方式是指融合系统按人预先设计的功能模型为探测数据赋予含义，以连续更新态势；自底向上方式则是指基于获取的数据不断对所关注态势进行验证，支持人修改和重塑关注的态势及行动假设，并力图发现和建立新的态势。这两种知识转换方式皆由 HAC 通过人机界面完成，旨在实现全局态势的优化判定和全局活动的动态规划。其中，计算代理通过已知（假设）的各种态势要素组合为穷举集合，来达成一个态势判断；而人则擅长通过智能认知和思维推理达成一个新的态势判定，并进一步感知变化的态势周边关系。

## （3）基于 HAC 的信息融合模式

基于人与融合计算的紧密耦合、融合与应用的紧密耦合，将 HAC 中的信息融合产生分为 4 种模式，如图 3.21 所示。

**自动信息融合模式：**基于传统 IFS 工作模式，增加了用户参与 IFS 设计功能，包括用户参与 IFS 需求、操作、界面、分发功能和样式的设计。

**判定信息融合模式：**基于自动融合模式，将人（操作员、控制员和指挥员）的判断结论信息，包括人的经验推理判定信息、灵感思维推理信息及不假思索的直觉判定信息等自动融入 IFS 相应判定环节，生成基于用户判定的融合结果。

行动信息融合模式：基于以上两种融合模式产生的融合结果，在时间和空间上进一步优化控制战场感知行动（如传感器配置与控制、分布融合节点资源分配调整以及融合算法配置和参数调整等），将可能产生的行动预测信息和已产生的行动结果信息融入 IFS，生成基于优化感知控制行动的融合结果。

应用信息融合模式：基于以上三种融合模式产生的融合结果，以嵌入或非嵌入方式融入应用系统中，将可能产生的应用事件和结果预测及能够收集到的事件结果信息融入 IFS，产生基于应用效能的融合估计结果。该融合模式将 IFS 直接与应用系统紧密耦合起来，能实现感知—融合—应用的闭环优化控制，类似于 Boyd 的 OODA 环<sup>[35]</sup>。

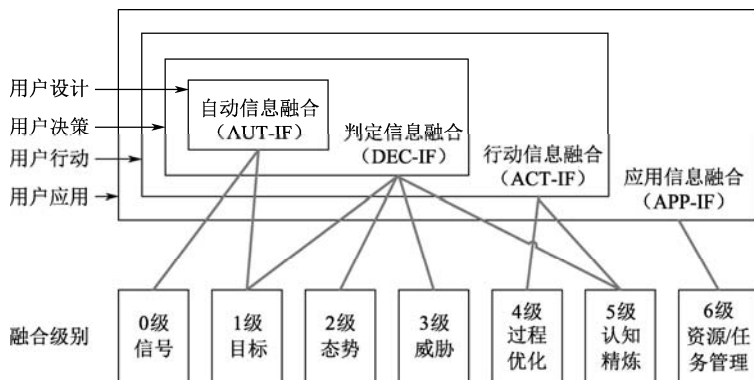


图 3.21 4 种融合模式及其与融合级别的关系

#### （4）人机界面优化设计活动

人机界面是实现人参与和主导信息融合，实现融合与应用紧密耦合的不可或缺的技术途径，因此人机界面的优化设计是实现各项用户精炼活动的关键部件<sup>[31,32]</sup>。尽管许多文献都提到界面问题（如多模态界面<sup>[53,54]</sup>），但对于融合学界来说，主要关注人机界面对认知类问题的优化支撑。此外，基于认知本体开发初始缺省信息，构建分布节点的融合时机转移分布，以及开发减少信息维度和不确定性等方法均与人机界面的优化设计紧密相连。

人机界面优化设计主要考虑的准则有 7 项：

- 一致性：界面应当与经验、习惯一致，且便于推理使用；
- 可视化友好结构：界面组织包括均衡性、对称性、规律性、可预测性、经济性、统一性、成比例、简洁性，以及可组合等；
- 分组：形态学（Gestalt）提供了屏幕元素的空间组合准则，包括邻近、相似、共用区、连通性、连续性，以及闭合等准则；
- 信息量：信息过多会导致混乱。采用“人在短期记忆中无法记住超过 $7 \pm 2$ 项”的米勒法则，基于启发式的截断数据能使屏幕上增加更多相关信息；
- 理性排序：元素排序组织有利于所关注的任务和处理活动获取需要的信息；
- 可区分性：关注的对象要能够与其他对象和背景区分开来；
- 关注点与着重点：对象的突出特征能够反映关注点的相对重要性。

#### （5）HAC 中的人机交互活动与分类

信息融合系统存在多类需要人参与、通过人机交互实现的认知活动,包括相悖信息调整,自动融合结论与用户直觉差异的消解,人对多结论的选择,时空事件应急处理,态势估计与威胁判断,以及融合性能评估和应用效能评估等,皆需人在图像界面或表格界面上通过人机交互进行认知判定。

HAC 中的人机交互活动分为预测行动、反应行动、预先行动和被动行动等 4 类,各类活动的性能如表 3.2 所示。

表 3.2 用户交互活动分类及其性能

行 动 类 型	时 间 延 误	推 理 能 力	需 求 范 围	应 用 时 限
预测的	规划的	有一些	之内	未来
反应的	立即的	无	之内	现在
预先的	预期的	强、积极	超出	更远的未来
被动的	潜在的	无或延时	超出	现在

### 3.7.3 人—代理集合体 (HAC) 中的用户控制与管理

#### 1. 人在感知环中的作用

Boyd 的 OODA 环<sup>[35]</sup>是人类认识世界和改造世界的普适规律。感知活动的 OODA 环及人在其中的作用如图 3.22 所示。

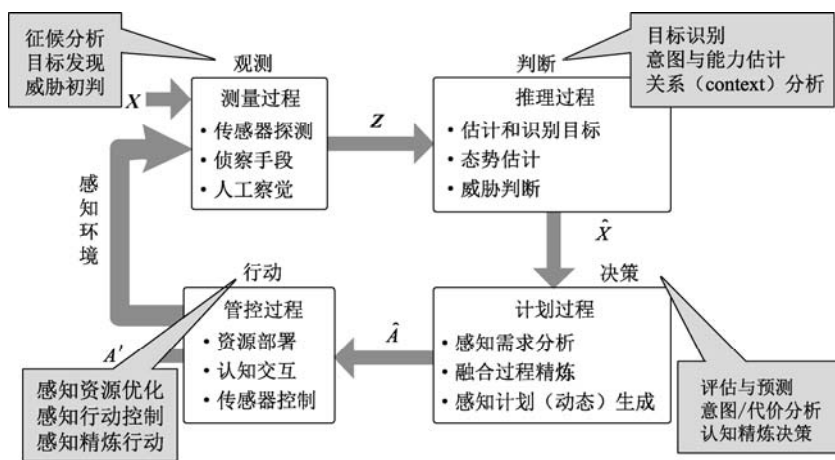


图 3.22 感知活动的 OODA 环及人在其中的作用

该 OODA 环中各环节都需要人的参与和主导,图 3.22 中各环节说明框中内容表示人在相应环节中发挥的作用。

为了获得战场信息优势,作战双方进行信息博弈,包括在 OODA 各环节采用伪装、隐蔽和欺骗 (CC&D) 措施及控制行为,力图实现对感知行动的闭环控制,使战场态势向有利于己方作战活动的方向演进,如图 3.23 所示。

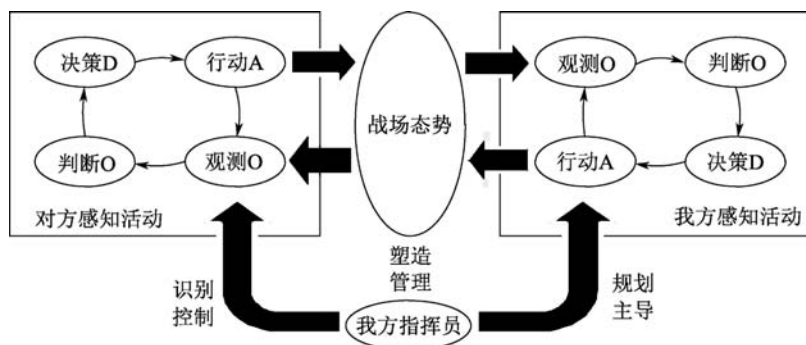


图 3.23 人对感知环的控制作用

图 3.23 中，我方指挥员对敌方感知活动的识别与控制包括：估计敌方对战场信息的可能观测和判断结果（包括敌方对我 CC&D 的识别结果），识别敌方行动计划和采取的 CC&D 措施与行动等；对我方感知活动的规划主导包括：基于估计的敌方行动和获取的环境信息，规划/控制/调整我方感知活动（包括 CC&D 措施）；对战场态势的塑造与管理包括：基于对敌方感知活动的识别和我方感知活动的规划，随作战任务和战场态势变化主导敌我双方作战活动，塑造符合我方作战意图的战场态势，掌握战场制信息权。

## 2. 人的控制与管理活动

### (1) 传感器控制与管理

包括预先规划探测需求（以天为单位）、设计探测平台位置和机动路线（以小时为单位）、控制传感器监视区域（以分为单位）和捕获目标（以秒为单位）。控制传感器感知方式，包括固定类（获得目标状态当前值）、事件类（预测目标状态出现变化的事件）、触发类（仅在目标状态出现变化时，启动感知测量）、动向类（记录一段数据，实现目标动向感知）和偏移类（检查超过门限的动向，指示态势变化预警）。

### (2) 人机交互管理

用户对系统有多种管理模式，如一个目标检测与跟踪案例中采用 3 种管理方式：①无知式管理：关闭自动融合显示，完全采用人对原始显示信息的感知手动控制；②接受式管理：完全采用融合结果，对应于系统自动融合能力；③交互式管理：人与系统输出进行适应性关联推理，对应于人与系统交互融合能力（详见文献[18]10.4.3 节），其中交互式管理模式是融合 HAC 设计的最佳选择，它能够充分发挥融合系统自动性能，并使操作人员参与尽可能多的融合级别，以改善和提升融合能力。

图 3.24 给出了这 3 种管理方式下的融合系统性能分析。我们知道，在目标检测中，用户希望接收具有高发现率（HR）和低虚警率（FAR）目标；而在目标跟踪中，用户希望跟踪尽可能多的目标并形成尽可能长的连续跟踪航迹。从图 3.24（a）、（b）中我们可以看到，接受式管理优于无知式管理，而人机交互式管理优于接受式管理。

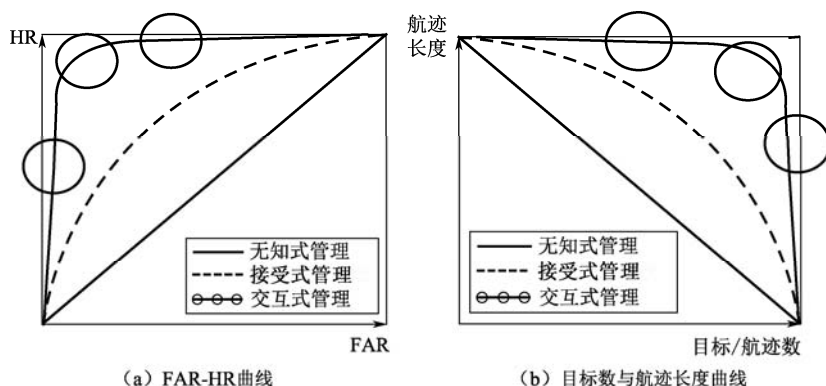


图 3.24 3 种管理方式下的融合系统性能分析

### (3) 人对系统功能度量的控制活动

信息系统的应用效能取决于融合信息的质量，它也是衡量系统复杂性和可用性/可操作性的重要依据。一个融合系统即使达到了系统设计的容量、精度、延时等要求，但在运行应用中，人的认知能力仍可能成为系统服务质量（QOS）的瓶颈。该问题频繁出现在态势感知的察觉级，对飞行事故的统计表明，缺少察觉产生的事故占 77%<sup>[36]</sup>，成为影响识别与判断能力，从而导致空难的主要因素。

信息系统质量的度量通常选择适时性、准确性、信息容量、可靠性/可信性、安全性、代价等指标，文献[18]描述了信息系统质量的共性指标及其在几个应用科目中的具体体现，如表 3.3 所示。

表 3.3 信息系统质量的几个科目度量指标

共 性 指 标	人的控制因素	信息融合指标 A	TR/ID 指标	航迹处理指标
时延	反应时间	适时性	目标发现或提取处理时间	航迹更新率
错误概率	可信度	可信度	发现概率和虚警概率	检测概率
误差方差	注意力	精确性	位置精度	误差协方差
流量	工作量	流量	图像帧数	目标数
安全性	信赖性	可靠性	认可程度	相容性
代价	代价	代价	搜索平台	资源数量

由表 3.3 可以看出，在信息质量指标中，人的各项控制因素与人的能力有关，并且需要将其转换为任务管理质量和系统管理指标才能实现。因此，建立系统功能度量中人的控制因素指标，成为用户与技术专家共同面对的问题。

### 3.7.4 用户在人—代理集合体（HAC）系统评估中的作用

HAC 系统的能力评估是由用户与专家共同完成的，由于 HAC 系统是为应用服务的，因此其效能评估必须以用户为主导。HAC 系统效能评估是基于其质量指标体系进行的，用户参与系统评估旨在基于系统应用中收集的信息，设计相应质量指标计算模型，并基于指标计算结果评估系统质量。信息融合系统的用户评估活动的一个设计与应用案例见文献[30]第 10 章。

在分布式信息融合系统中,探测平台和用户通过网络实现信息互通、协同运行。因此需要严格评估网络连接方式和各节点的局部效用及系统全局效用,以实现全局信息效用的优化。在分布式融合系统中,与用户密不可分的主要评估活动主要包括两个方面:

### (1) 系统响应能力评估

响应能力包含系统的适时性和准确性,以及容量和安全性等指标,是分布式融合系统应用能力的主要体现。基于 HAC 的融合系统的响应能力应通过将各级操作者的作用加入到系统中进行评估和验证。在分布式信息融合系统中,信息从获取、传输,直到各节点的融合与分发都会产生信息延迟和误差,因此,需对整个系统的响应能力进行评估,特别是对态势与威胁估计或应用层面上的作战决策等高层认知系统,在这其中,人的认知和判定是不可或缺的因素。

在分布式融合 HAC 系统中,判定时间与信息到达时间通常有两种情况:

① 判定持续时间短于数据到达时间间隔,这会导致判定采用的数据不足,产生缺乏人的认知流的后果,使判定结论偏离关注的目标。

② 判定历时长于新数据到达时间间隔,这会产生判定数据遗漏,导致判定依据不充分或不完整,使人的判定结论偏离真实态势。

这两种情况均与人的因素有关,因为判定时间与人的认知能力密不可分,而评判基于人的认知能力评估系统响应能力存在较大难度。

### (2) 系统质量指标体系的评估

对信息系统质量指标体系的评估主要是指人对评估指标体系的合理性和基于应用需求的质量指标选择。需从以下三方面考虑:

一是从具体的用户任务需求选取融合 HAC 系统质量指标体系,例如,作战决策系统要求态势和威胁判断的准确性,但并不要求高精度、高实时性;火力打击则要求高精度、高实时性,反导系统对打击目标精度和实时性要求比对常规武器平台的引导要求高得多;战略预警系统关心的是目标最先发现与识别时间和可能覆盖的时空范围,即早期预警而不是精确位置等。因此,不能千篇一律地用一个指标体系去衡量各种应用的信息质量需求。

二是质量指标体系内的许多指标之间具有关联性,例如,决策的准确性与耗费时间有关,安全性又与系统响应能力相互依赖,系统覆盖目标的完整性与系统响应时间有关,信息传输的安全(加密)性与传输时间有关等。因此在确定融合系统的质量指标数值时,对于相互影响的指标,可以基于特定的任务需求,突出某一重点关注指标的作用,赋予较严格的指标值。

三是质量指标的合理性检验问题,为了使质量指标体系符合用户需求,用户需要对确定的质量指标进行验证和评估,评估时要考虑多方面因素对质量指标的影响,例如,信息的准确性受信息内容的有效性(信息是否来自目标的各分量)、结构有效性(实体结构与其他同样潜在结构的相关程度),以及相关准则的有效性(如实体或态势与某些任务的相关性)的影响;这些有效性参数只能由用户定义,并通过操作员和控制员的操作和认知判定结果进行验证和评估。

### 3.7.5 人—代理集合体（HAC）设计中的挑战与机遇

#### 1. HAC 设计中的挑战性问题

网络中心战中的人—代理集合体（HAC）分散配置在各平台或节点上，通过网络协同工作。分布式信息融合系统中的 HAC 的信息和控制功能广泛散布在大量潜在的自关注代理中，即分布在各融合节点上，并且每个融合节点的用户具有不同意图、不同目标和不同的融合效用需求。分布式信息融合系统的 HAC 设计既要考虑各节点用户的局部意图和目标，又要对整个融合系统的应用意图、目标和需求进行全局考虑。这些特点使分布式信息融合系统 HAC 设计出现下述挑战性问题：

- 提供灵活的自治性。各节点融合计算代理在某些时间可以不考虑用户意见，不响应人的干预，以完全自主的方式运行；在其他时间接受与关键决策关联最密切的人的指导行动，即响应最邻近节点人的干预，按其意图运行。
- 自组织机制。建立一种使融合计算代理与人构成的集合体，能够灵活组织机制，以获得一个特定的合作（性能和效能）基线，达到任何个体无法单独达到的目标，并且一旦合作行动完成（达到预期目标），该集合体即予以解散。
- 设立激励工程的详细准则。对行动者的回报设计为：在联合（集合体存在）时能够鼓励参与者积极行动，以产生全局期望的结果。
- 设计和开发一个可计算的信息基础设施。采用一种健壮、可靠的方式，把传感器与对其探测数据赋予含义的人融合到一起，以提升对变化态势感知的节奏，并开发一种机制来确认和审查信息的真实性和精确性。

从 3.1 节～3.6 节的论述中很容易发现上述 4 个问题的踪迹，也就是说，这 4 个问题也正是分布式战场感知与信息融合所面临的诸多难点，亟待建立新学科，以达成对现实世界中的 HAC 的理解、建立和运行。不难看到，该新学科无疑要采用本章所给出的分布式信息融合设计中的许多原理和方法，当然还需要其他学科提供的洞察力、理解力和方法论，如人工智能、基于代理的计算、机器自主学习、合作系统及云计算等。

#### 2. HAC 的可能应用领域

如果上述挑战性问题能够解决，会帮助我们应对所面临的信息化战争和一些关键社会挑战，如生存性、兼容性、安全性等对我们未来至关重要的难题。除了当前军事领域的网络中心战之外，预期能获得重大效益的 4 个民用应用领域如下：

##### （1）抢险救灾

对水灾、火灾、地震、海啸、火山喷发、核泄漏等自然/人为灾难响应，亟需有效的营救服务，这要对一个不确定性和快速变化的态势进行准确的判断。因此，开发一个 HAC 系统才能使主要响应者和计算代理在该态势中有效工作，包括通过各种信息源（如闭路电视，无人/有人飞行器，各类传感器和侦测手段，以及人工手段）收集该环境中尽可能多的信息，经正确分析和决策，有效管理和使用可用的各种救援资源，协调各种救援活动，以得到尽可能大的救援效果。达成该目标所需要的关键技术有：①分布式合作算法，能在缺少中心

控制的情况下有效分配资源,如3.3节提出的关于信息资源和网络资源的全局优化分配算法,以及传感器协同工作和网络中各自利平台的协调方法等;②灵活的自主处理方法,软件代理的自主判断和决策要能够随救援需求和态势变化而改变,并能对人的指挥控制快速响应,从而减少灾难损失;③对信息和决策来源的跟踪能力,以识别信息的不确定程度和决策的准确性,并随着新的信息出现和救援目标的变化迅速对之前的决策予以更新,保证救援行动连续、高效进行。

### (2) 能量栅格

亟待开发一个现代化的能量电子栅格,其中信息沿能量消费和能量生产两个方向流动,以达到减少全球碳排放的目标。该能量栅格实质上是一个人—代理集合体(HAC)系统,例如,采用能量代理(能量状态估算设备)能够连续监视、预测和反馈该栅格中的能量耗费和生产状况,以满足各用户对成本、碳排放和耗能设备的协调、优化选择需求。支持该HAC目标的技术需求有:①联合信息算法,能使多个自关注方,如可再生能源与消费者,一起建立虚拟电厂,以更有效地管理这些能源的生产和消费周期;②开发能量需求和近期供应预测算法,以优化能量的使用效益;③建立可计量的信息基础设施,以保证提供给用户的智能计量装置更加容易理解、可信和可审计。

### (3) 平民参与领域

当前,针对传统计算领域的挑战性问题,许多科研项目越来越多地求助于平民科学家来帮助解决。HAC则有助于平民的参与,它能够对项目志愿参与者参与问题的深度、使用的技巧和偏好及能力等方面进行观察和评估。为了在这些设置的项目中有效利用志愿参与者,需研发的技术有:①模拟和预测平民提供内容的精度和信赖度的算法;②跟踪和收集平民收集信息来源的方法和数据模型;③建立一种基于志愿者能力学习模型的询问机制。

### (4) 反恐领域

当前,反恐和反极端组织成为世界各国的共同目标和不可推卸的责任。HAC在反恐领域大有可为,它能够将对多源信息的分析和判断与融合推理计算结合起来,分析和确定恐怖主义产生的动因,跟踪恐怖主义源头,为采取有效应对和防范措施及有力的打击手段提供支撑,需开发的技术有:①基于历史数据的行动特征分析与预测算法;②基于大数据的多域行为来源关联模型;③多介质信息融合恐怖行为识别算法;④在恐怖行为出现时,可将其视为一种灾难,采取“抢险救灾”领域的HAC有关关键技术。

## 3.8 本章小结

本章描述了分布式信息融合的概念,提出了网络中心战环境中战场感知信息融合所面临的6个关键问题,并给出了解决方法。其中有的问题是传统集中式融合就存在的,有的是分布式信息融合提出的新问题。相关或相关性未知的信息融合问题在集中式融合中就已存在,但在分布式融合情况下,由于信息重复使用增多,相关性增强,该问题已不可避免。本章给出了有界协方差增长(BCI)方法,对相关或相关性未知信息融合误差进行分析和控制。传



感器协同控制是指各传感器探测状态（目标指向）及基于网络的探测信息分发协同问题，是战场感知系统必须进行的全局考量的问题。本章给出的极大和算法就是基于传感器状态与网络资源约束进行多点融合全局效用考量，寻求传感器最优协同运行状态。感知网络中个自利平台（代理）的协调是分布式信息融合面临的新问题，它通过寻找基于传输信道衰减的传感器探测信息的最优多级传输路径，使信息产生的局部和全局效用（信息量或精度）达极大，采用拍卖机制寻求网络带宽的多级最优分配来实现这一目标。合同信用估计问题也是分布式信息融合提出的新问题，通过统计计算网络中各合作代理的合同交付概率及其协方差来估计合作对象的信用，为代理选择合作对象提供依据，本章给出了两种计算方法（独立贝塔分布和卡尔曼滤波）达到这一目标。本章最后给出的基于人—代理集合体（HAC）的分布式信息融合，突显了人在分布式信息融合中的主导作用。当今正在兴起的 HAC 方法已成为分布式信息融合未来必然采取的技术途径，其中描述的 HAC 设计问题和可能的应用领域使我们明确看到了这一点。

本章描述的新概念、新方法和案例源于作者对文献[1]和文献[18]、[30]的理解，以及作者自身的研究成果和经验。可能会有不足甚至错误之处，请读者予以指正。

## 参考文献

- [1] David L Hall, Chee-Yee Chong, James Llinas, et al. Distributed Data Fusion for Network-Centric Operations. Chapter 2.
- [2] Kaupp T, A Makarenko, F Ramos, et al. Human Sensor Model for Range Observations. IJCAI Workshop Reasoning with Uncertainty in Robotics, Edinburgh, Scotland, July 2005.
- [3] Reece S, S J Roberts. Robust, low-bandwidth, multi-vehicle mapping. Proceedings of the Eighth International Conference on Information Fusion, Philadelphia, PA, 2005.
- [4] Durrant-Whyte H F, M Stevens, E Nettleton. Data fusion in decentralized sensor networks. Proceedings of the Fourth International Conference on Information Fusion, Montreal, Quebec, Canada, 2001, 302–307.
- [5] Julier S J, J K Uhlmann. General decentralized data fusion with covariance intersection (CI). In Handbook of Multisensor Data Fusion, Stochastic Processes. New York: Wiley, 2001.
- [6] Doob J L. Stochastic Processes. New York: Wiley, 1990.
- [7] 张贤达. 矩阵分析与应用. 北京: 清华大学出版社, 2004.
- [8] 周概容. 概率论与数理统计. 北京: 高等教育出版社, 1986.
- [9] 数学手册编写组. 数学手册. 北京: 人民教育出版社, 1979.
- [10] Rogers A, A Farinelli, R Stranders, et al. Bounded approximate decentralized coordination via the max-sum algorithm. Artificial Intelligence, 2011, 175(2): 730–759.
- [11] Waldock A, D Nicholson. A framework for cooperative control applied to a distributed sensor network. The Computer Journal, 2011, 54(3): 471–481.
- [12] Dash R, A Rogers, S Reece, et al. Constrained bandwidth allocation in multi-sensor information fusion: A mechanism design approach. Proceedings of the Eighth International Conference on Information Fusion,

- Philadelphia, PA, 2005.
- [13] Rogers A, R Dash, N R Jennings, et al. Computational mechanism design for information fusion within sensor networks. Proceedings of the Ninth International Conference on Information Fusion, Florence, Italy, 2006.
- [14] Reece S, A Rogers, S J Roberts, et al. A multi-dimensional trust model for heterogeneous contract observations. Proceedings of 22nd AAAI Conference on Artificial Intelligence, Vancouver, British Columbia, Canada, 2007a, 128–135.
- [15] Reece S, A Rogers, S J Roberts, et al. Rumours and reputation: Evaluating multi-dimensional trust within a decentralized reputation system. Proceedings of Sixth International Joint Conference on Autonomous Agents and Multi-Agent Systems (AAMAS-07), Honolulu, HI, 2007b, 1063–1070.
- [16] Bar-Shalom Y, X R Li, T Kirubarajan. Estimation with Applications to Tracking and Navigation. Hoboken, NJ: Wiley Interscience, 2001.
- [17] Dash R K, D C Parkes, N R Jennings. Computational mechanism design: A call to arms. IEEE Intelligent Systems, 2003, 18(6): 40–47.
- [18] 赵宗贵, 刁联旺. 信息融合工程实践——技术与方法. 北京: 国防工业出版社, 2015.
- [19] Martin E Liggins, David L Hall, James Llinas. Handbook of Multisensor Data Fusion: Theory and Practice (Second Edition), CRC Press, Taylor & Francis Group, Boca Raton London, New York, 2008.
- [20] Blasch E P, P Hanselman. Information Fusion for Information Superiority. IEEE National Aerospace and Electronics Conference, 2000.
- [21] Blasch E P. Ontological Issues in Higher Levels of Information Fusion: User Refinement of the Fusion Process, International Conference on Information Fusion, 2003.
- [22] Blasch E P. Assembling a Distributed Fused Information-based Human-Computer Cognitive Decision Making Tool, IEEE Aerospace and Electronic Systems Magazine, May 2000, Vol.15, No.5, 11-17.
- [23] David L Hall, Sonya A H McMullen. Mathematical Techniques in Multisensor Data Fusion(Second Edition). Artech House Inc, Boston/London, 2004.
- [24] Steinberg A N, Bowman C L, White Jr F E. Revision to JDL Data Fusion Model. Proceedings of the 3rd NATO/IRIS Conference, Quebec City, Canada, 1998.
- [25] Hall M J, Hall S A, Tate T. Removing the HCI Bottleneck: How the Human Computer Interface(HCI) Affects the Performance of Data Fusion System. Proceedings of the MSS National Symposium on Sensor and Data Fusion, San Diego, CA, Jun, 2000, 89-104.
- [26] Steinberg A N, Boxvman, C L, White F E. Revisions to the JDL Data Fusion Model, Proceedings of SPIE, 1999, Vol. 3719.
- [27] U S Office of Management and Budget (OMB) Circular A-130. <http://www.whitehouse.gov/omb/circulars/a130/a130trans4.html>.
- [28] Blasch E. Sensor, User, Mission (SUM) Resource Management and Their Interaction with Level 2/3 Fusion, International Conference on Information Fusion, 2010.
- [29] Blasch E, I KadaL, J J Salerno, et al. Issues and Challenges of Knowledge Representation and Reasoning

- Methods in Situation Assessment (Level 2 Fusion). Proceedings of SPIE 6235, 2006.
- [30] 赵宗贵, 熊朝华. 信息融合概念、方法与应用. 北京: 国防工业出版社, 2012.
- [31] Blasch E. Proactive Decision Fusion for Site Security. International Conference on Information Fusion, 2005 .
- [32] David L Hall, A Steinberg. Dirty Secrets in in Multisensor Data Fusion. Proceedings of National Symposium on Sensor Data Fusion(NSSDF), San Antonio, Tx, June, 2000.
- [33] 杨露菁. 多传感器数据融合手册. 北京: 电子工业出版社, 2008.
- [34] CJCSI 3151.01. Global Command and Control System Common Operational Picture Reporting Requirements. 10, June, 1997.
- [35] Hightower T A. Boyd's OODA Loop and How We Use It. [http://www.tacticalresource.com /d/node/226](http://www.tacticalresource.com/d/node/226).
- [36] Eric Blasch, Eloi Bosse, Dale A. Lambert, High-Level Information Fusion Management and Systems Design, ARTECH House, Boston/London, 2012.

# 第 4 章 分布式融合结构与估计算法

## 4.1 引言

许多应用领域如目标跟踪、机器人、环境保护、地质勘探、医疗诊断以及制造业中的生产过程监视与控制都越来越多地开始使用传感器（数据源）提供观测信息，为后续的决策和行动提供依据。多传感器在分散配置的较大地域和更宽阔的频谱范围内以及更持久的时间上比单一传感器具有更大的搜索范围，并且多传感器对更大时空频域的更多观测信息进行融合处理，能够改善事件检测，降低虚警。基于多传感器独立观测信息的融合能够改善目标的定位和识别精度，例如处于不同位置的同类传感器（如雷达）采用对象的不同观测视角能够提供目标位置更精确的测量，而异类传感器（如雷达和红外/光学传感器）能够观测对象的不同特征以更准确地识别该对象。特别是在当前出现隐身目标（如 B2 远程战略轰炸机的 RCS 只有  $10^{-3} \text{m}^2$ ）的战场环境中，表现为弱信号目标（包括自身是小目标如无人机、巡航弹、弹道目标和机动目标等）观测，此时单一传感器已无法跟踪甚至无法发现这类目标。在这种情况下，多视角、多频段、多介质、多平台传感器组网探测成为弱信号目标检测的有效手段。

多传感器测量信息可以在一个中心点或在地理上分散的多点进行处理或融合，分别被称为集中式融合和分布式融合。集中式融合结构要求所有测量信息通过理想信道（及时、无误差）传输到一个单一点，由于没有任何中间处理环节产生的测量信息损失，故其在理论上是最优的，但要以较高的传输带宽为代价，并且融合信息要统计独立。在分布式融合结构中，每个处理站点负责处理来自一个或多个传感器（信息源）的测量信息，然后将处理结果传送给下游融合节点做进一步处理，由于各站点的融合信息量大大低于原始测量信息量，因此传输处理结果只需较低的通信带宽；并且融合处理负荷被分散到多个站点上，使处理负荷均衡以降低系统脆弱性（单点失效对全局影响较小）；然而，分布式结构中的各融合节点分散处理会产生原始测量信息损失，因此在理论上无法达到集中式融合的优化效果。

由于分布式信息融合的上述优点和应用领域的需求，已出现许多分布式融合系统应用案例，如以网络为中心的战场感知系统（见第 2 章）、机器人群组以及无线传感器网络（WSN）等。这些案例并不适用于集中式处理，而分布式结构则比较适宜。然而，为了使分布式处理达到尽可能高的次优融合效果，出现了许多新的问题需求，其中一些是集中式融合业已存在却被忽视或不被重点关注的问题，如融合输入信息的相关性；还有一些是分布式融合必须解决的新问题。与集中式融合相比，分布式融合面临的新的求解问题主要有两大类：第一类是选择合理的融合结构，包括传感器与处理器或融合站点（应用代理）如何连接，融合节点之间及其与应用节点之间如何连接，以在网络带宽资源约束下确定适宜的信息流向和传输内容等，从而使感知网络的全局效用达极大。本书第 3 章中将第一类问题分解为信息重复使用引起的相关性（有些文章

称为依赖性或非独立性)、多传感器协同探测与信息分发、各自利平台(代理)的协调以及代理(合作对象)的信用估计问题等,并分别描述了求解各个问题的技术途径和方法。第二类问题是在确定的网络结构和信息传输方式下,每个网络节点(代理)如何选择融合处理来自多类节点数据的估计算法,如解除显式相关信息算法、考虑隐式相关的启发性次优算法以及分布式感知系统中的新问题处理算法,以弥补系统资源和融合结构的不足,尽可能达到全局优化性能。

本章首先描述分布式信息融合结构及分布式融合信息图,并基于信息图跟踪系统信息流向,在应用容许条件下改变网络结构以避免信息重用,同时采用贝叶斯估计算法避免多源非独立(相关)信息重用。然后重点介绍在确定的分布式融合结构下建立最优和次优全局估计的通用算法,包括仅采用各局部估计的全局融合算法和基于各局部估计与全局先验估计的滤波算法。最后给出了目标跟踪和对象识别中的分布式估计算法,其中对象状态可以是连续时变的(如目标跟踪中,飞行器的位置和速度),而对象的属性通常是离散的(如对象分类识别)。

本章各节内容安排是:4.2节介绍分布式融合结构,描述融合结构依赖因素及其对融合效能的影响,在此基础上给出分布式融合结构的选择基准和结构分类;4.3节介绍分布式融合信息图,重点描述几类多连接信息图向单连接信息图的转换,特别是给出了全对等式(播放式)信息图的两个实际应用案例;4.4节介绍分布式估计算法,描述贝叶斯分布估计中的重用信息去除原理,给出最优贝叶斯分布融合算法及其在各类分布融合结构中的实现公式,还描述了4种次优贝叶斯分布融合算法以及高斯分布或带有误差协方差估计的全局估计算法,包括极大后验(MAP)估计、最优线性无偏估计(BLUE)和交叉协方差(CC)融合算法;4.5节介绍目标跟踪中的分布式估计通用方法;4.6节介绍对象分类识别的分布式估计方法;4.7节对本章内容进行总结。

最后再一次强调指出,与集中式信息融合相关性概念不同,本章所提及的分布式信息融合中的相关性是指信息获取非统计独立,如共用过程噪声、共用先验信息等引起的信息重复使用产生的信息相关性。

## 4.2 分布式信息融合结构

一个分布式融合系统的基本部件是传感器、处理器(统计估计器或融合计算代理)和用户(应用系统)。传感器产生来源于关注对象的测量或数据,包括对象状态信息,如位置、速度或属性特征(分类);传感器测量还包含杂波、虚警和噪声。估计器或融合代理对传感器数据或从其他代理接收的处理结果进行处理,以生成关注对象的最优估计。用户是融合结果的使用者,一个用户可以是一个过程监视系统、作战指挥系统、机器人系统或业务信息系统中的控制部件或决策人员。在一个分布式融合或估计系统中可能存在多个传感器、处理器和用户,他们在地理上通常是分散部署的,并通过通信网络连接起来协同工作。

### 4.2.1 融合结构的依赖因素

分布式融合结构依赖下述4类因素,它们相互依赖地影响融合结构的选择。

① 信息传输。即传输路径、信息量/占用网络带宽。节点之间传输的数据是传感器测量或其处理结果、信息处理节点的融合结果;传输路径要在传输信息量和带宽资源之间进行优

化选择,以避免资源冲突并以获得最大信息效用为目标;要尽量减少同一信息(相关信息)的重复传输,以减少网络资源占用并避免信息重复使用。

② 共用先验信息。在传输融合结果(对象估计及其误差协方差)时,通常需要增加下游融合节点所需要的先验信息,如网络拓扑或信息谱系,以记录信息传输路径、识别共用节点,为消除信息重复使用提供依据;最优融合需知悉所有获取的新信息,若缺少信息或缺少信息的充分统计量,融合只能是次优的;对于有偏估计的目标跟踪来说,需要多个之前时刻的状态估计知识作为当前融合的先验信息;若仅知道当前状态,融合也只能是次优的。

③ 过程噪声。指目标状态中混杂的动态噪声和杂波,它与传输速率、传输内容/信息量、融合层次间信息流向等一起对融合性能产生重要影响。

④ 融合算法。对不同的网络结构和通信带宽,需选择适宜的融合估计算法,不能一味追求高精度和优化。贝叶斯估计和次优贝叶斯估计以及某些近似算法,分别适用于不同背景(如信息相关、不相关和相关性未知等)和条件(高斯分布、带协方差的估计量等),可根据应用需求进行选择(见本章4.4节)。

## 4.2.2 融合结构与依赖因素之间的关系

图4.1给出了两层次分布式融合结构中过程噪声、传输速率、融合层次之间信息流向,以及传输的信息内容等因素对融合性能 $A/A^*$ 的综合影响效果<sup>[22-25]</sup>。




图4.1 融合结构依赖因素对融合性能的影响

图 4.1 是分别针对传输速率  $n=1,2,4,8$  ( $n-1$  表示传输延迟周期数) 以及过程噪声  $q$  在较大范围内 ( $10^{-4} \sim 10^6$  dB) 变化的 3 种融合结构的融合性能图, 其中图 4.1 (a) 表示无反馈层次融合结构, 图 4.1 (b) 表示有反馈层次融合结构, 图 4.1 (c) 表示有部分反馈融合结构。每个结构的性能图都是基于对一批匀加速运动目标的 5 000 个模拟测量样本采用信息矩阵融合算法 (即高斯随机向量贝叶斯融合算法的信息矩阵形式, 其在信息独立条件下是最优的) 进行仿真实验所产生的。图 4.1 中横轴为过程噪声, 纵轴为融合性能  $A/A^*$ , 其中  $A$  为全局融合航迹误差协方差椭圆面积,  $A^*$  为融合输入的各局部估计误差协方差椭圆面积的平均值。每张图最上面的长划线表示采用交叉协方差 (CC) 融合算法 (其性能通常低于信息矩阵融合算法) 提供的 4 种通信速率下融合性能曲线的一个极大似然 (ML) 误差上界。

图 4.1 (a) 给出的无反馈层次融合结构是一个基于命令逐级上报的网络结构, 该结构能随时增补探测源, 改善可观测性, 扩展探测监视能力, 获得最优的目标航迹估计。在该图 4 种传输速率下, 全局融合相对误差  $A/A^*$  随过程噪声的增加而减少, 这说明在噪声较大时, 融合效果更显著。当  $n=8$  时, 由于时间延迟过大, 大大减少了全局融合更新采用的局部信息量, 使全局融合误差接近 ML 估计的误差上界 (当  $q=10^{-1} \sim 10^2$  dB 时); 当  $n=1$  时, 全局融合及时得到各局部估计结果并进行实时融合更新, 故全局融合误差最小。从该图还可以看到, 这 4 种传输率下全局融合误差曲线之间差别不大, 说明合理延迟不会严重影响系统性能。

图 4.1 (b) 给出的有反馈 (全反馈) 层次融合结构是一个局部融合节点具有自主跟踪功能的结构, 此时局部融合节点需要维持其最小估计误差协方差, 实时 ( $n=1$ ) 反馈结构不影响局部节点自主估计结果; 当噪声较小 ( $q < 10^2$  dB) 时, 有延迟 ( $n > 1$ ) 的反馈信息对局部自主估计结果影响较小; 而当噪声较大 ( $q > 10^2$  dB) 时, 有延迟的反馈信息对局部自主估计结果影响较大, 会出现比 “无反馈层次结构” 更坏的全局融合结果, 这是由于全局融合误差协方差较大 (实际上是由于融合算法没有完全解除所有信息相关因素, 从而产生不真实的全局融合误差协方差矩阵, 详见第 6 章), 其反馈信息会使局部节点融合误差协方差增大, 无法维持其最小估计误差协方差, 从而影响其自主跟踪能力, 并最终导致全局融合误差协方差急剧增长。

图 4.1 (c) 提供的带部分反馈的层次融合结构是指仅将全局状态估计 (不含估计误差协方差) 反馈给含有不稳定误差协方差的部分局部节点。在这里, 全局节点的目标状态估计误差较小, 其误差协方差由于失去真实性而变得很大。故该部分反馈就能减少局部节点的不稳定性, 从而可以避免全反馈结构反馈的大误差协方差导致的局部融合误差快速增长, 使局部融合能够维持其最小估计误差协方差。

图 4.1 给出的这个案例表明了 3 种 (无反馈、有反馈、部分反馈) 层次融合结构、通信延迟 ( $n=1,2,4,8$ )、过程噪声 ( $q:10^{-4} \sim 10^6$  dB) 对全局融合性能 ( $A/A^*$ ) 的综合影响, 从中可以看出, 在确定的融合算法 (信息矩阵融合算法) 下这 3 类因素之间及其与全局融合性能之间的关系。或者说, 在确定的全局融合性能指标下, 融合结构的选择依赖于通信传输能力、信息流向、传输内容、过程噪声和融合算法。最后需指出的是, 层次结构中的反馈信息会产生局部节点融合中的信息重用, 从而会增加信息的相关性, 这也是产生融合误差协方差增长的一个因素。由第 3 章介绍的有界协方差增长 (BCI) 方法可以看到, 分析和控制信息之间的相关性是很复杂、难于操作的问题, 这也正是在层次化系统中人们不愿意使用信息

反馈机制的原因之一。该案例没有描述不同的融合算法对全局融合性能的影响以及融合算法与其他影响因素之间的关系,这是我们在4.4节中的研究内容。

### 4.2.3 分布式融合结构的选择基准

基于上述对分布式融合性能的影响因素及其相互关系案例的分析,确定分布式信息融合结构选择的几个基准如下:

- 一个网络节点要能够访问尽可能多的传感器原始测量信息,因此感知网络要连接尽可能多的传感器,并在通信带宽约束下将传感器信息分发给尽量多的融合节点;
- 接入某融合节点的信息(测量信息或上游节点融合信息)具有较大的噪声或协方差,才能体现出融合产生的信息具有显著的质量提升,包括信息精度和属性识别率的提升;
- 为在通信带宽约束下实现信息高效传输,需有效压缩传输数据。层次融合结构除与应用需求紧密耦合外,还要具有压缩信息量的能力,因此,各层次融合节点需要寻求输入信息和产生输出信息的最小充分统计量,以减少带宽占用,尽量避免通常逐层融合产生的信息损失;
- 在层次结构中,要慎重考虑信息反馈问题,要尽量避免全局节点将不真实的估计误差协方差反馈给局部节点,并且局部节点要控制反馈信息内容和使用密度,以保持局部融合误差协方差最小,实现局部自主最优跟踪;
- 在满足局部节点应用需求之下,融合结构要尽量减少共用节点信息为下游节点重复使用,以减少信息相关或相关性未知状态,以抑制融合误差协方差增长;
- 融合结构所连接的节点,要考虑节点的信用和信息效用,以及是否具有全局考量,要避免连接并尽可能剔除对网络全局感知效用增益小,甚至具有负面效应的自利节点;
- 网络可以使用提高健壮性/生存能力的冗余路径,以提高信息的可达性。冗余路径的使用要具有可控性,以避免导致较多的通信带宽和处理负荷,以及多连接路径产生的信息重用引起的相关性;
- 网络化分布式融合结构的局部和全局指标,如目标信息量或精度、目标识别准确性、时间延误及发现率和虚警率等,可根据具体应用业务需求确定,不应设置不适宜的高指标。

### 4.2.4 分布式融合结构分类

分布式融合结构由三个部分组成<sup>[26]</sup>:通信图(也称网络连接图)表示系统各基本部件之间的网络连接能力,信息图表示传感器的多时刻测量到处理器的信息流程,第三个组成部分就是传输的信息内容。

分布式融合结构以融合结构图的形式出现,其在概念上表示通信网络确定的融合系统连通性,图中各节点表示传感器和处理器,有向边线表示相应部件之间的通信路径。基于具体的传感器到处理器之间的通信路径数量(广义上讲应是网络中任两个节点之间的通信路径数量)可以分为两种主要类型的融合结构图:单连接融合结构图和多连接融合结构图。



## 1. 单连接融合结构图

在单连接结构图中,任意一对传感器—处理器之间只存在一条单一(单向)路径。图 4.2 给出了单连接结构的 4 个例子:集中式、解耦式、重复集中式和无反馈层次结构。

在图 4.2 (a) 给出的集中式结构图中,所有传感器测量传递到一个单一融合节点或代理进行处理。在理论上,该结构不存在信息损失而产生最优融合性能;然而,集中式结构意味着网络的高通信负荷和融合节点的高处理负荷,而且由于一个融合节点的失效会产生系统融合效能的降低。图 4.2 (b) 给出的解耦式结构图把传感器分为两组,一个融合节点负责处理一组传感器测量,该结构适用于传感器自然分类,如按地域或按类型或按介质分类,使同一组中的传感器能相互辅助,而组外传感器只能对该组提供少量额外信息。解耦式结构具有最低的通信和计算负荷,但当传感器无法轻易划分时,该结构性能会较差。在如图 4.2 (c) 所示的重复集中式结构中,多个融合节点处理来自同一(或某些)传感器的测量数据,但各融合节点之间并不进行通信。由于多融合节点处理同一传感器数据,故重复集中式结构具有较高的性能和可靠性,但也要付出较高的通信和处理代价。图 4.2 (a)、(b)、(c) 所示的三个结构图都不允许融合节点之间进行通信,因此从传感器到一个融合节点就只有一条信息路径。由于不存在重复计算问题,这三个结构容许使用简单的集中式融合算法,从而作为其他复杂的分布式融合结构性能比较的基准。

在如图 4.2 (d) 所示的无反馈层次结构图中,融合节点按层次排列,低层节点处理传感器数据以形成局部估计,局部估计又被发送到高层融合节点进行全局融合。为达到减少通信负荷的目的,从低层节点到高层节点采用的通信率可以低于传感器观测率。与集中式结构相比,当低层节点处理的数据来自较小的传感器观测集合时,层次结构具有较低的通信和处理负荷,并能够增加系统可靠性;但若每个传感器和融合节点收集和处多时刻测量数据时,传感器与融合节点之间会出现多条信息路径,这是由于低层节点某一时刻的融合结果在向某其他高层节点传输的同时,还作为自身节点某一后续时刻的先验信息,融合产生向其他高层节点传输的信息,从而出现同一传感器信息在不同时刻向同一高层节点发送两次,即存在两条或两条以上传感路径。这样看来,无反馈层次结构尽管在空间上看是单连接的,但在信息传输流程图中各时间点之间仍可能出现多条路径,详见后面图 4.5 (b) 无反馈两层次结构信息图。

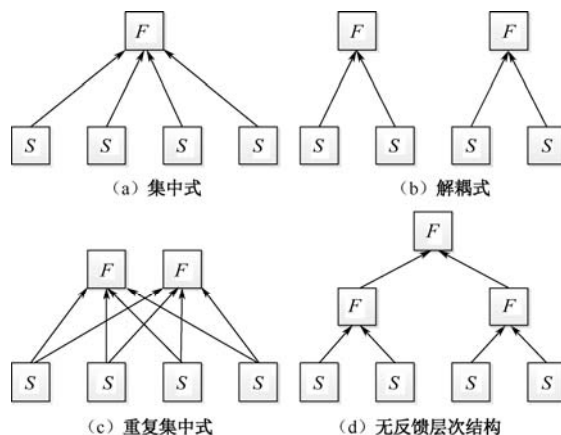


图 4.2 单连接融合结构图

## 2. 多连接融合结构图

在多连接结构图中，一对传感器与处理器之间存在多条通信路径。图 4.3 给出了多连接融合结构的 4 个例子：传感器共享层次式、反馈层次式、邻近对等式和播放式。

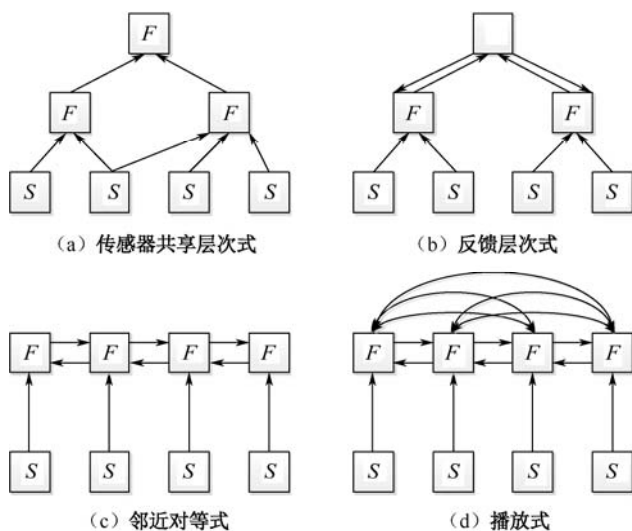


图 4.3 多连接融合结构图

在图 4.3 (a) 给出的传感器信息共享层次式结构图中，一个传感器测量可以由多个高层融合节点进行处理，而这多个高层融合节点又相互通信，从而在传感器与某些高层节点之间产生两条通信路径。该结构对发挥高性能传感器的效用很有意义，但由于无法消除同一传感器信息重复使用产生的相关性，使高层节点对两低层节点估计信息的融合出现较大误差。在图 4.3 (b) 给出的反馈层次式结构图中，高层融合节点的精确估计（含有更多的传感器信息）被反馈给融合传感器数据的低层节点，能够提升该低层节点的融合精度（或增加其信息量）。低级节点与高级节点之间存在信息双向流动的两条通信路径，故低层节点在融合高层节点的反馈信息时，两次使用了自身估计信息，产生信息相关性。

在图 4.3 (c) 给出的邻近对等式结构图中，一个融合代理仅与其邻近的代理之间存在双向信息流动，即有两条通信路径；而在图 4.3 (d) 给出的播放式结构图中，每个融合代理都将其融合结果播放给所有其他融合代理，即每个融合代理与所有其他融合代理之间都存在双向信息流动，即存在多条通信路径。播放式融合结构又被称为全对等分布融合结构，其中一个节点响应所有其他节点的播送信息请求。该结构中的信息传输是动态出现的，并不预先规定，这对于高实时、高精度和高一致性感知需求的多平台作战系统具有重要应用价值。

一般说来，多连接融合结构具有较强的健壮性和抗毁性，但是在算法开发上比较困难，因为多条信息路径产生的信息重复使用会导致信息的强相关性，对于当前已有的信息融合技术来说，尚无成熟的融合算法。

## 4.3 分布式融合信息图

分布式融合结构图在高层次（空间）上表示网络节点之间的信息传输路径，并不描述测量信息或融合信息在该网络中怎样流动，因此无法在时间上刻画上游传感器或融合节点与下游融合节点之间信息实时传输状态。而这恰恰是识别上游共用节点信息在下游节点出现数据混杂所需要的。分布式融合信息图<sup>[6-10, 27]</sup>则表示基于通信路径确定的融合结构中按时序产生的信息流和事件，因此能够支持最优和次优融合算法的开发。一个类似的图模型可在文献[28, 29]中找到。

信息图中的节点（信息节点）表示某一时刻的信息事件，其中观测节点表示一个传感器在一个确定时刻的观测事件，融合节点表示一个融合站点在一个确定时刻进行的一个融合事件，融合事件有三个主要类型：多个传感器测量的局部融合、传感器测量与局部估计结果的融合，以及多局部估计结果的全局融合。

信息图中的有向边线或连线表示信息节点之间的通信。其中观测节点是没有前辈的叶节点，其后续节点始终是融合节点。一个融合节点的前辈可以是观测节点或其他融合节点（指本融合节点的前辈节点或其他融合节点）。一个融合节点的后续节点可以是其他融合节点或没有后续节点。通过信息图中连接某节点的边线可以跟踪对该节点有用的信息。从节点 A 到节点 B 的有向边线表示节点 B 访问节点 A 处的信息，每个节点通常访问其前辈节点，从那里获得的具体信息依赖于通信传输能力（速率、信道衰减、错码率等）。观测节点到融合节点传输的是传感器数据，而融合节点之间通常传输的是融合估计结果，如果估计信息是融合输入信息的充分统计量，则融合节点处最大的信息量就由所能追溯到的所有原始观测节点传感器数据组成。

分布式融合信息图提供了一个有用的工具，用来发现和识别被某下游融合点融合的两个或两个以上上游节点估计所采用的共用信息，此时，该下游融合节点对该共用信息使用了两次（或以上）。若两融合节点有共用的原始观测节点，这两节点的融合估计就含有该共用的传感器的同一观测数据；若两融合节点没有共用的前辈节点，则除自身先验信息外，没有其他共用信息。

### 4.3.1 单连接信息图

单连接信息图是指信息图中两信息节点之间只有一条有向边线或连线，其与单连接融合结构不是一个概念，如单连接融合结构中的无反馈层次结构的信息图就是多连接的。

图 4.4 给出了图 4.2 中描绘的集中式、解耦式和重复集中式等单连接融合结构的信息图。

从这 3 张图可以看出，每个信息图中观测节点到融合节点，以及各融合节点（父子节点）之间都只有一条单一有向边线，故都是单连接信息图。这 3 张信息图都只有一个融合层次，只有在重复集中式信息图中，两融合节点共享一个传感器观测数据，但由于这两个融合节点没有同一后续节点，因此不存在对一个传感器观测数据的重复使用问题。

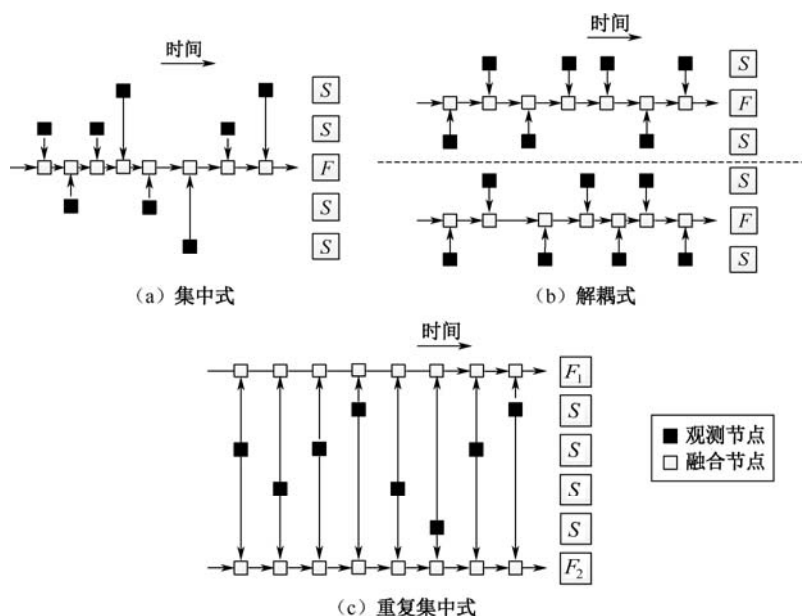


图 4.4 3 种单连接融合结构的信息图

### 4.3.2 无反馈层次融合的多连接信息图及连接转换

无反馈层次融合结构图是单连接的，但其信息图都是多连接的，这是由于某一上游共用节点信息向某一下游节点重复传输与融合产生的。无反馈两层次融合结构及其信息图如图 4.5 所示。




图 4.5 无反馈两层次融合结构及其信息图

从图 4.5 (b) 可以看出， $F_1$  和  $F_2$  的局部融合节点  $H$  和  $L$  都有前辈节点  $\bar{L}$ ，即在  $H$ 、 $L$  的融合信息中都包含了  $\bar{L}$  节点的共用信息，这样一来， $H$ 、 $L$  融合信息在  $F_3$  节点进行全局融合时就两次使用了该共用节点信息。或者说融合节点  $\bar{L}$  与对  $H$ 、 $L$  节点信息进行融合的  $F_3$  节点之间存在两条信息路径，从而导致  $F_3$  节点全局融合出现对  $\bar{L}$  信息的重复使用。

为了避免信息重用产生的相关性，可以通过修改通信策略和处理方式，将该多连接信息图变换为单连接信息图。基本思路是避免在全局（ $F_3$  的动态节点）融合中重复使用某一局部

融合节点信息，图 4.6 给出了两种变换方法：局部重启和全局重启。

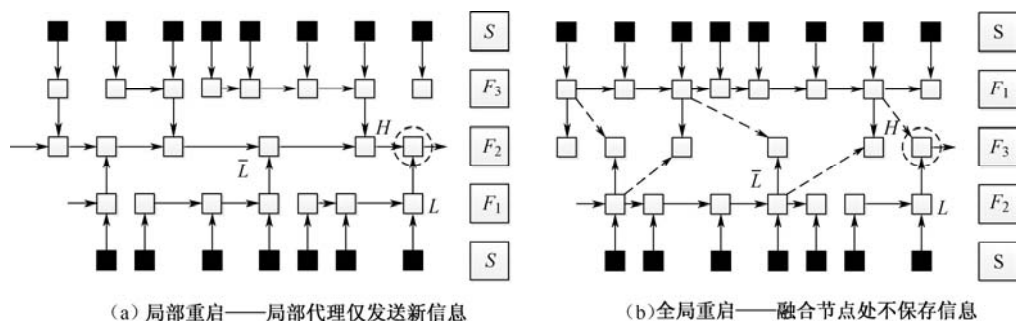


图 4.6 无反馈层次融合信息图单连接转换

在图 4.5 (a) 给出的无反馈层次融合信息图中，由于融合节点  $F_1$ 、 $F_2$  的局部融合信息来自其传感器观测和自身上一时刻的先验信息，为了使其向  $F_3$  发送的信息不重复，必须使每次局部融合生成的上报信息采用不同的传感器观测数据，即  $F_1$  和  $F_2$  每次仅发送自上次向  $F_3$  发送之后获得的新的观测数据的局部融合结果，这等价于在每次发送之后即断开从  $F_1$ 、 $F_2$  向自身下一时刻节点发出的有向边线，或者说随下一观测数据的到来重新启动局部融合节点，称为局部重启，即相当于在  $F_1$  和  $F_2$  处设置一个以发送间隔划分的离散通信输出估计器。

图 4.6 (b) 描绘的全局重启是指全局节点  $F_3$  在每次融合之后删除向自身下一时刻节点发出的有向边线，或者说， $F_3$  在各次全局融合之间处于单一离散状态。从该图中可以看到， $F_3$  每次全局融合仅对  $F_1$  和  $F_2$  上报的局部融合信息进行，融合结果也不作为先验信息参与下一次全局融合，因此  $F_3$  节点不保存任何融合信息。从图 4.6 (b) 还可以看到， $F_3$  相邻的两次融合信息量之差就是  $F_1$  和  $F_2$  向  $F_3$  的两次上报之间获得的新信息（传感器数据），因此每次全局融合都没有重复使用任何测量信息，从而不会产生信息重用现象。

对于带有共用传感器的共享层次融合结构，其信息图中共用传感器与高层融合节点之间有多条路径，故呈多连接信息图形式，如图 4.7 (b) 所示。由于每条路径必须通过传感器与高层节点之间的低层融合节点（这是由低层融合节点跟踪需求确定的），故难以转换为单连接形式。

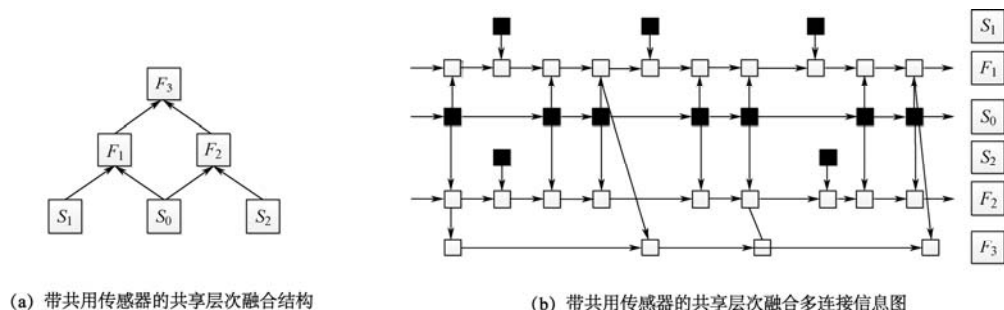


图 4.7 带共用传感器的共享层次融合结构与信息图

### 4.3.3 有反馈层次融合信息图及连接转换

有反馈两层次融合结构与信息图如图 4.8 所示。

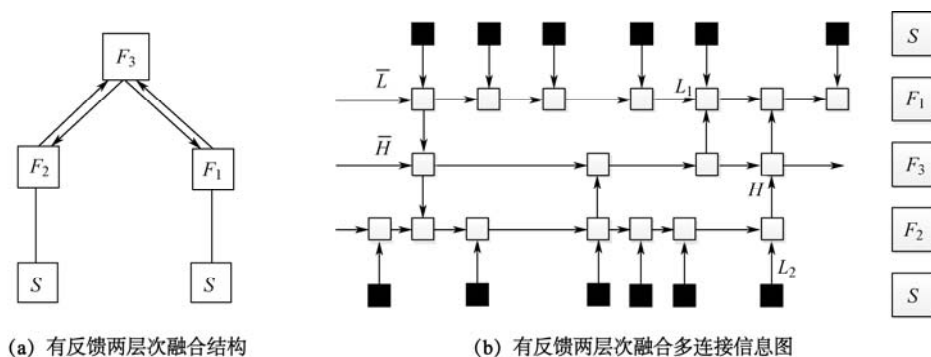


图 4.8 有反馈两层次融合结构与信息图

从图 4.8(b)可以看出,这是一个多连接信息图,如从 $\bar{L}$ 到 $L_1$ 存在三条路径,从 $\bar{H}$ 到 $H$ 存在两条路径等。假设无反馈层次融合情况,若这里的局部融合站点所发送的融合信息不依赖于最后一次通信之前的反馈或传感器观测,则在高层进行全局融合的多连接信息图可以转换为一个单连接网络。实际上,局部站点需要保存两组信息,第一组是使用所有传感器观测(包括反馈信息)融合生成的局部最优估计,以实现局部站点对目标的最优自主跟踪;第二组是仅依赖最后一次通信之后接收的新的局部观测或其他局部融合结果,作为向高层站点发送的无重复观测段(即分段观测)集合。通过删除适当的边线,在低层站点进行全局融合也能够转换为一个单连接结构图。图 4.9(a)、图 4.9(b)分别给出了低层全局融合和高层全局融合向单连接转换生成的信息图。

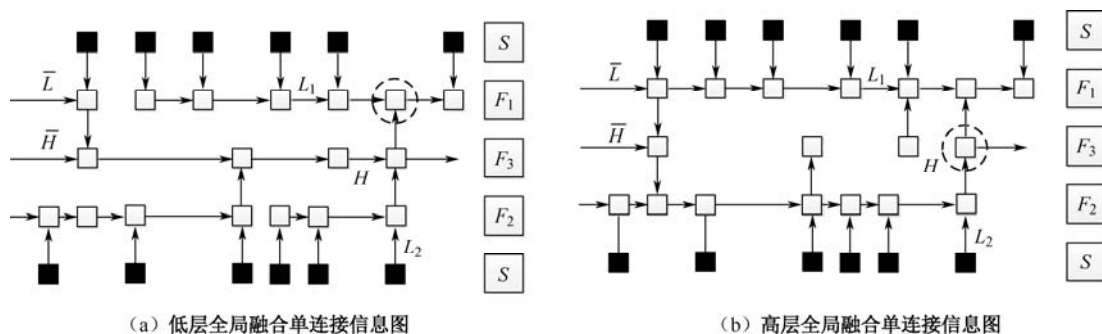


图 4.9 有反馈层次融合单连接信息图

### 4.3.4 对等式分布融合信息图及连接转换

对等式分布融合信息图包括邻近对等式、全对等(播放)式及循环分布式等融合信息图。

#### 1. 邻近对等融合信息图

邻近对等融合结构与信息图如图 4.10 所示。从图 4.10(b)可以看出,在 4 个邻近对等融合节点信息分发过程中,任意两节点之间存在多条路径,随时间增加,最多出现 4 条路径,即为多连接信息图。如果每个融合站点向邻近站点仅发送最近通信之后接收的新信息(或新信息的融合信息),则其融合信息图变成单连接,如图 4.10(c)所示。

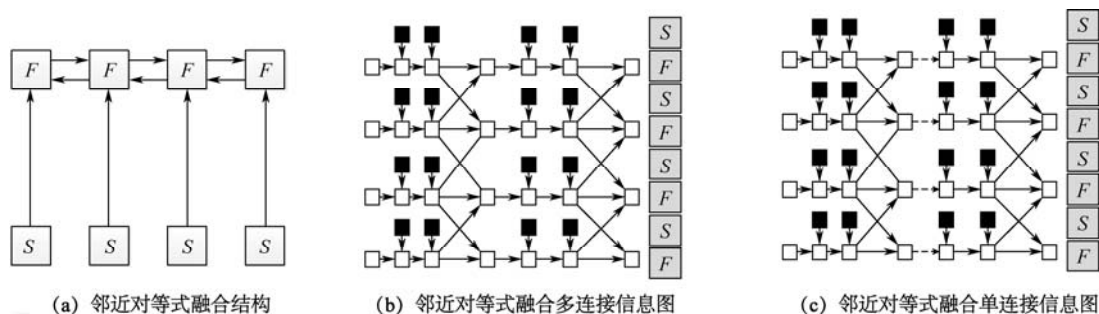


图 4.10 邻近对等式融合结构与信息图

邻近对等式融合节点无层次之分，每个节点的融合结果既要向邻近节点发送，又要支持与自身耦合的作战应用，故其通常要建立两类融合机制：

- 融合节点对所有来源信息（既含有自身传感器探测信息，又含有邻近节点传递来的融合信息，以及自身上一时刻的先验信息）进行融合，以获得最大信息效用，支持自身节点的作战应用（如局部自主跟踪目标）并发送给下一时刻自身节点，该融合信息只为节点自身使用，不用于对外发送。
- 仅融合节点自身的阶段测量信息（即仅对最近一次向邻近节点发送后自身传感器的新探测信息进行融合），用于向邻近节点按阶段发送。图中的有向虚线表示节点自身阶段测量信息融合是断开的，即前述的局部重启或全局重启融合概念，以保持每次发送的融合信息之间不含重复测量信息。

## 2. 全对等（播放）式融合信息图

全对等（播放）式融合结构与信息图如图 4.11 所示。




图 4.11 全对等（播放）式融合结构与信息图

与邻近对等式融合信息图是多连接一样，播放式融合信息图也是多连接的，如图 4.11 (b) 所示。为了将其转换为单连接信息图，要进行与邻近对等式融合信息图类似的变换，即每个融合节点在对所有其他节点上一次播放融合信息之后，断开与自身下一节点的连接，重新积累自身传感器所产生的新观测信息，以融合产生下一次播放信息，即每次播放信息之间不含重复测量信息。图 4.11 (c) 所示的单连接信息图中的有向虚线与图 4.10 (c) 中概念类似并且也要像邻近对等融合一样，在每个融合节点建立两类融合机制，以维持每次播放信息

之间的无关(不重复)性,支持网络感知的全局最优;同时保持节点自身融合信息的最优性,以支持相应的作战应用需求。

美国海军海上编队协同防空作战系统(CEC)采用编队各舰全对等式数据融合结构,该结构将对等分发功能由局部融合节点扩展到传感器测量节点,实现多舰火控传感器探测信息的实时共享。该系统采用各舰火控传感器探测信息先分发后融合机制,由于每艘舰船获取的目标信息在空间、频段、时间和范围上具有互补性,故先分发后融合机制使每艘舰船在一个周期内都能获得关于空中目标相同的信息内容和信息量,从而融合生成连续一致的目标航迹,形成各舰一致的单一目标合成空图(SIAP)<sup>[31]</sup>,支持对空中来袭目标的协同打击作战行动,包括各舰火控雷达对空中目标的复合跟踪,多舰防空火力对打击目标的协同发射(集火射击),以及多舰接力制导等协同作战行动<sup>[32]</sup>。为使编队各舰实时获取与融合生成关于同一打击目标相同的 SIAP,用于传输火控传感器观测数据的全速率数据网络(DDS,数据分发系统)带宽达 48 Mb,能使远程 30 英里距离和本舰 30 英尺距离上对信息传输容量、可靠性和时间延误达到同等水平。图 4.12 描绘了 CEC 对一批来袭目标(巡航导弹)的复合跟踪示意图。




图 4.12 CEC 对一批来袭目标的复合跟踪示意图

播放式融合结构的另一个实际应用案例是局部对等测量分发融合机制。图 4.13 描绘了一批空中目标  $T$  从防空责任区  $M_1$  跨越防区交接线进入防空责任区  $M_2$  时,两相邻责任区对该目标航迹所采取的两种交接方式——硬交接方式和软交接方式。

由图 4.13 (a) 可以看出,两防空责任区  $M_1$  和  $M_2$  按硬交接线  $S$  划分并进行目标航迹交接,即当目标  $T$  从左向右飞行时,其位于硬交界线左侧  $M_1$  区内的航迹由  $M_1$  区所辖雷达探测信息融合生成,而在右侧  $M_2$  区内的航迹则由  $M_2$  区所辖雷达测量融合生成。这样一来,当






图 4.13 目标跨区飞行航迹的两种交接方式

目标跨越硬分界线  $S$  飞行时, 通常会出现航迹间断或偏移现象 (如图 4.13 (a)  $M_1$  中的航迹位置  $B$  与  $M_2$  中交接时刻该目标航迹的位置  $C$  之间的偏移), 这种航迹跳变会产生目标速度和航向估计值的跳动变化, 导致无法对该目标进行跨区连续平滑跟踪, 进而对目标跨区的拦截作战活动产生诸多不利影响。为了克服这一弊端, 提出一种如图 4.13 (b) 所示的目标航迹软交接方式, 该方式利用责任区  $M_1$  与  $M_2$  存在的探测覆盖区  $M = M_1 \cap M_2$ , 在一批目标由左向右跨区飞行的过程中, 当目标位于  $M_1 \setminus M_2$  (指去掉  $M_1$  的探测覆盖区部分) 区域内和  $M_2 \setminus M_1$  区域内时, 仍按传统方式, 即两区基于自身所辖雷达测量在其融合中心  $F_1$  和  $F_2$  分别生成该目标航迹, 然后传递到全局融合中心  $F_3$ 。而当目标位于覆盖区  $M$  内时, 凡是探测到该目标的雷达 (不管其隶属哪个责任区), 皆将该目标探测信息同时对等分发给两责任区  $M_1$  和  $M_2$  的融合中心  $F_1$  和  $F_2$  进行融合, 然后传递到全局融合中心  $F_3$ 。图 4.13 (b) 所示的目标航迹软交接方式的融合结构与信息图如图 4.14 所示。




图 4.14 目标航迹软交接方式的融合结构与信息图

图 4.14 (a) 中的有向虚线表示覆盖区  $M$  中目标的测量对等分发给两辖区融合中心, 此时  $F_1$  和  $F_2$  获得完全相同的探测信息, 在理论上  $F_1$  和  $F_2$  应生成完全一致的目标航迹。由此可见, 在目标由左向右跨区飞行态势下, 目标从  $M_1 \setminus M$  区域飞入  $M$  的过程中, 会逐渐增加  $S_2$  测量信息, 而从  $M$  飞入  $M_2 \setminus M$  区域过程中, 会逐渐减少  $S_1$  测量信息。这样一来, 全局融合中心  $F_3$  获得的该目标航迹不会发生间断、偏移等跳变现象, 从而实现了跨区目标的实时、连续、平滑跟踪, 如图 4.14 (b) 所示。对目标的两种跨区交接方式在工程应用中的航迹实

际跟踪效果对比如图 4.15 所示。




图 4.15 两种跨区交接方式在工程应用中的航迹实际跟踪效果对比

### 3. 循环分发式融合信息图

融合结果的循环分发方式是对等式分布融合的一种特殊形式,其融合结构与信息图如图 4.16 所示。




图 4.16 循环分发式融合结构与信息图

由图 4.16 可见,循环分发融合的结构图和信息图都是多连接的,其中节点  $F_1 \rightarrow F_3 \rightarrow F_2 \rightarrow F_1$ ,即各节点融合信息循环发送。该融合机制既无法划层次,也无法识别新信息。从图 4.16 (b) 描绘的信息图可以看出,  $B$  和  $C$  具有两个共用前辈节点  $D$  和  $E$ ,而  $D$  和  $E$  又有两个共用前辈节点  $F$  和  $G$ 。于是可以看出  $A$  点融合对  $D$ 、 $E$  点信息各使用两次(各重复使用一次),  $B$  点融合对  $F$ 、 $G$  点信息各使用两次(各重复使用一次)等。不难看出,图 4.16 (b) 给出的信息图无法转换成单连接结构。

## 4.4 分布式估计算法

### 4.4.1 分布式估计概述

分布式估计研究大约始于 1980 年,近 30 年来的研究成果的概要介绍见文献[1]和[2],

主要面向基于各局部估计建立全局最优估计问题<sup>[3-5]</sup>。1982 年美国国防部先期研究规划局 (DARPA) 制定的分布式传感器网络 (DSN) 计划确定研究任意结构的通用分布估计方法<sup>[6-9]</sup>, 使用信息图跟踪系统中的信息流, 所建立的最优融合算法能避免计算中重复使用同一 (相关) 信息和数据混杂。DSN 计划还开发了通用分布式目标跟踪算法<sup>[1,10]</sup>, 1990 年, 英国和澳大利亚的研究人员开发了类似的避免信息重用和数据混杂的分散融合算法<sup>[11,12]</sup>, 以及协方差交集 (CI) 算法<sup>[13,14]</sup>, 用于处理被融合的局部估计之间的未知相关性。1986 年, Bar Shalom 和 Campo 开发了使用各局部估计之间的交叉协方差 (CC) 的第一个融合算法<sup>[15]</sup>, 随后是文献[16,17]给出的最优线性无偏估计 (BLUE) 融合算法, 以及文献[18,19]给出的极大后验 (MAP) 融合准则。文献[20]和[5]还包含了融合算法的性能评估问题。

分布式融合估计的目的是基于提供给每个融合站点的有效信息生成每个融合站点的最优估计, 可提供局部用户应用; 然后假设将这样的局部估计 (或概率分布) 而不是原始测量传递到全局融合节点或应用节点, 产生全局最优融合结果, 提供给全局用户应用。由于局部融合压缩了测量数据, 故传输局部估计仅需要较低的通信带宽。

当传输原始测量数据时, 与传统集中式融合类似, 估计算法可以假设测量信息之间具有统计独立性或所估计的状态之间具有条件独立性。然而, 当全局融合针对各局部估计进行时, 这些条件独立性很可能丧失, 这是由于被融合的某些局部估计含有共用信息产生的局部估计之间的相关性所致。需要指出的是, 4.2 节中虽然描述了将分布式融合多连接信息图转换为单连接, 以消除上游共用信息为下游重复使用引起的相关性, 但是在许多情况下, 如无层次之分的循环分发式融合结构, 具有共用传感器的层次融合结构, 以及某些支持局部节点特定应用信息需求的分布式融合结构, 均无法或不允许将多连接信息图向单连接转换。此外, 由于无法事先知晓通信带宽约束下的网络传输信息流 (传输路径、传输内容、融合节点层次以及是否存在信息反馈等), 因此多连接信息图向单连接转换只能是一种理论上的途径。即便知晓网络信息传输流程, 修改传输路径还要受到通信带宽、应用需求、信息增益等限制, 操作起来也绝非易事。另一种情况是, 由于对目标的状态测量不充分 (或不完整), 某些融合算法无法基于测量获得所需要的状态参数估计。以上种种问题均成为人们开发分布式估计算法的动因。

本节重点描述为避免信息重复使用引起的相关性, 以及被融合信息的相关性已知或未知情况所采用的最优和次优分布式融合估计算法。

#### 4.4.2 贝叶斯分布估计中的重复信息去除原理

设  $x$  是要估计的对象状态, 它可以是一个连续随机变量, 如对象的位置、速度, 也可以是一个离散的随机变量, 如一个对象的属性分类。设  $p(x)$  是状态  $x$  的先验概率密度函数或离散变量的概率分布。假设信息图中两个局部融合节点的关注区域 (ROI, 即责任区)  $Z_1$  和  $Z_2$  获得的对象测量集合是

$$\begin{aligned} Z_1 &= \{Z_{11}, Z_{12}, Z_{13}, \dots\} \\ Z_2 &= \{Z_{21}, Z_{22}, Z_{23}, \dots\} \end{aligned} \quad (4.1)$$

这些测量可以在不同时刻或同时来自多传感器, 假设每个测量分量对状态  $x$  是条件独立

的,并且这些测量在传感器之间和在时间上也是相互独立的,则它们的联合概率密度函数可分解为

$$p(z_{ij}, \dots, z_{mn}, \dots | x) = p(z_{ij} | x) \cdots p(z_{mn} | x) \quad (4.2)$$

若两融合节点的关注区域 (ROI, 即责任区)  $Z_1$  和  $Z_2$  具有重叠范围, 则可以进行信息分解, 如图 4.17 所示, 其中仍用  $Z_1$  和  $Z_2$  表示落入关注区域中的测量集合。




图 4.17 两个相互覆盖关注区域中目标测量集合的分解

从而得到:

$$Z_1 \cup Z_2 = (Z_1 \setminus Z_2) \cup (Z_2 \setminus Z_1) \cup (Z_1 \cap Z_2) \quad (4.3)$$

式中,  $Z_i \setminus Z_j$  表示从  $Z_i$  中去除与  $Z_j$  的重叠部分,  $Z_1 \cap Z_2 \neq \emptyset$  是由于某个或某些传感器对关注区域重叠范围内对象的测量要同时报送  $Z_1$  和  $Z_2$  所致。

贝叶斯分布估计包含: 两局部融合节点分别基于各自的测量集计算局部后验概率  $P(x | Z_1)$  和  $P(x | Z_2)$ , 然后基于所有测量  $Z_1 \cup Z_2$  计算全局后验概率  $P(x | Z_1 \cup Z_2)$ 。

我们注意到, 在测量之间相互独立假设下, 下式成立

$$\begin{aligned} P(Z_1) &= P(Z_1 \setminus Z_2) P(Z_1 \cap Z_2) \\ P(Z_2) &= P(Z_2 \setminus Z_1) P(Z_1 \cap Z_2) \end{aligned}$$

从而  $P(Z_1)P(Z_2)/P(Z_1 \cap Z_2) = P(Z_1 \setminus Z_2)P(Z_2 \setminus Z_1)P(Z_1 \cap Z_2) = P(Z_1 \cup Z_2)$ 。于是在给出状态  $x$  及测量之间条件独立性假设 (4.2) 的情况下, 可以得到

$$\begin{aligned} p(Z_1 \cup Z_2 | x) &= p(Z_1 \setminus Z_2 | x) p(Z_2 \setminus Z_1 | x) p(Z_1 \cap Z_2 | x) \\ &= \frac{p(Z_1 | x) p(Z_2 | x)}{p(Z_1 \cap Z_2 | x)} \end{aligned} \quad (4.4)$$

对式 (4.4) 反复应用条件概率公式  $p(x, y) = p(x | y) p(y) = p(y | x) p(x)$ , 可以得贝叶斯分布式融合方程, 即基于测量的目标状态后验估计方程

$$p(x | Z_1 \cup Z_2) = \frac{p(Z_1 | x) p(Z_2 | x) p(x)}{p(Z_1 \cap Z_2 | x) p(Z_1 \cup Z_2)} = C^{-1} \frac{p(x | Z_1) p(x | Z_2)}{p(x | Z_1 \cap Z_2)} \quad (4.5)$$

其中

$$C = \frac{p(Z_1 \cap Z_2) p(Z_1 \cup Z_2)}{p(Z_1) p(Z_2)} \quad (4.6)$$

由于测量集合  $Z_1$  和  $Z_2$  都含有交集  $Z_1 \cap Z_2$ , 因此式 (4.3) 表示  $Z_1 \cup Z_2$  中的信息两次包含了交集  $Z_1 \cap Z_2$  中的信息, 因此基于  $Z_1 \cup Z_2$  进行的统计估计就两次使用了  $Z_1 \cap Z_2$  中的信息, 这是由于  $Z_1 \cap Z_2$  中的一次测量要同时报给两个 ROI 的局部融合节点, 当这两个局部节点进行全面融合时即产生对该测量信息的重复使用。这与两个独立或非独立传感器同时测量一

个目标, 获得该目标的两个测量不是一个概念。公式 (4.5) 表示该状态  $x$  的全局融合后验概率是局部后验概率  $p(x|Z_1)$  与  $p(x|Z_2)$  之积除以共用后验概率  $p(x|Z_1 \cap Z_2)$ , 即对交集  $Z_1 \cap Z_2$  中的信息重用一次产生的负面影响进行去除, 因其已在局部后验概率  $p(x|Z_1)$  和  $p(x|Z_2)$  中各包含了一次。由此可见, 贝叶斯融合方程 (4.5) 和 (4.6) 能够导出关注状态的最优融合方程关键在于识别出两关注区重叠区域及其中的共用信息, 去除它所产生的共用后验概率, 以避免重复使用该共用信息。这样一来, 利用贝叶斯后验融合除了需要两局部后验概率  $p(x|Z_1)$  和  $p(x|Z_2)$  之外, 还需要知道共用后验概率  $p(x|Z_1 \cap Z_2)$ , 这需要识别出重复使用的共用信息  $Z_1 \cap Z_2$ 。共用信息通常包含先验状态估计结果, 以及其中所包含的重复信息。其中先验状态估计主要来自全局融合节点自身上一时刻的融合结果, 有时也来自局部节点。重复信息则来自与全局融合节点直接连接信道输入的局部融合信息或传感器测量信息。为了在贝叶斯后验融合公式中去除共用信息, 需要逐级记录信息图中输入该节点的信息的上游传输路径, 以识别出逐级重复信息, 这要消耗大量信息负荷和存储资源。

两层次无反馈融合结构与信息图如图 4.18 所示。




图 4.18 两层次无反馈融合结构与信息图

在图 4.18(b) 中, 若仅考虑局部融合节点  $F_1$  在  $A$  点产生的共用信息为全局融合节点,  $F_3$  在  $E$  点融合时使用两次, 需要在融合时予以去除, 贝叶斯后验融合公式为

$$p[x|Z_{F_3}(E)] = C^{-1} \frac{p[x|Z_{F_1}(C)]p[x|Z_{F_3}(D)]}{p[x|Z_{F_1}(A)]} \quad (4.7)$$

若同时考虑  $F_1$  在  $A$  点产生的共用信息和  $F_2$  在  $F$  点产生的共用信息, 它们在全局节点  $F_3$  在  $E$  点融合时都使用两次, 则贝叶斯后验融合公式为

$$p[x|Z_{F_3}(E)] = C^{-1} \frac{p[x|Z_{F_1}(C)]p[x|Z_{F_3}(D)]}{p[x|Z_{F_1}(A)]p[x|Z_{F_2}(F)]} \quad (4.8)$$

### 4.4.3 最优贝叶斯分布融合算法

#### 1. 高斯随机向量的贝叶斯分布融合算法

假设状态  $x$  是带有已知均值和协方差的高斯随机向量, 并且测量是带有零均值和已知协方差的高斯随机向量, 则两个局部估计也是带有均值  $\hat{x}_1$ 、 $\hat{x}_2$  和协方差  $p_1$ 、 $p_2$  的高斯随机向

量。基于两个局部估计的全局估计也是具有均值  $\hat{\mathbf{x}}_{\text{IU2}}$  和协方差  $\mathbf{p}_{\text{IU2}}$  的高斯随机向量。此时全局融合方程 (4.5)、(4.6) 变为

$$\mathbf{p}_{\text{IU2}}^{-1} \hat{\mathbf{x}}_{\text{IU2}} = \mathbf{p}_1^{-1} \hat{\mathbf{x}}_1 + \mathbf{p}_2^{-1} \hat{\mathbf{x}}_2 - \mathbf{p}_{\text{I}\cap 2}^{-1} \hat{\mathbf{x}}_{\text{I}\cap 2} \quad (4.9)$$

$$\mathbf{p}_{\text{IU2}}^{-1} = \mathbf{p}_1^{-1} + \mathbf{p}_2^{-1} - \mathbf{p}_{\text{I}\cap 2}^{-1} \quad (4.10)$$

其中  $\hat{\mathbf{x}}_{\text{I}\cap 2}$  和  $\mathbf{p}_{\text{I}\cap 2}$  是共用信息的状态估计均值和协方差。由于协方差矩阵之逆是Fisher信息矩阵 (其表示信息精度), 故式 (4.9)、式 (4.10) 又被称为信息矩阵融合 (IMF)。式 (4.10) 表示全局融合估计的信息矩阵等于两局部估计信息矩阵之和减去 (去除) 共用信息估计矩阵, 式 (4.9) 表示全局估计信息等于两局部信息估计之和减去 (去除) 共用信息估计。因此, 全局融合除了需要知道局部估计  $\hat{\mathbf{x}}_1$ 、 $\mathbf{p}_1$ 、 $\hat{\mathbf{x}}_2$ 、 $\mathbf{p}_2$  之外, 还要知道共用信息  $\hat{\mathbf{x}}_{\text{I}\cap 2}$ 、 $\mathbf{p}_{\text{I}\cap 2}$ 。

信息矩阵融合 (IMF) 方程也可以直接从信息滤波方程<sup>[3]</sup>导出。设局部节点观测方程是

$$\mathbf{Z}_i = \mathbf{H}_i \mathbf{x} + \mathbf{v}_i \quad i=1,2 \quad (4.11)$$

式中,  $\mathbf{H}_i$  是观测矩阵,  $\mathbf{v}_i$  是零均值独立观测噪声, 误差协方差为  $\mathbf{R}_i$ 。则产生局部估计  $\hat{\mathbf{x}}_i$  的信息滤波方程为

$$\begin{aligned} \mathbf{P}_i^{-1} \hat{\mathbf{x}}_i &= \bar{\mathbf{P}}^{-1} \bar{\mathbf{x}} + \mathbf{H}_i^T \mathbf{R}_i^{-1} \mathbf{Z}_i \\ \mathbf{P}_i^{-1} &= \bar{\mathbf{P}}^{-1} + \mathbf{H}_i^T \mathbf{R}_i^{-1} \mathbf{H}_i \end{aligned} \quad (4.12)$$

式中,  $\bar{\mathbf{x}}$  和  $\bar{\mathbf{P}}$  是  $\mathbf{x}$  的先验估计 (预测) 均值和协方差。

给出两个相互独立的观测  $\mathbf{Z}_1$ 、 $\mathbf{R}_1$ 、 $\mathbf{Z}_2$ 、 $\mathbf{R}_2$ 。则基于这两个独立观测的全局最优估计  $\hat{\mathbf{x}}$  及其误差协方差  $\mathbf{P}$  由下述信息滤波方程给出:

$$\mathbf{P}^{-1} \hat{\mathbf{x}} = \bar{\mathbf{P}}^{-1} \bar{\mathbf{x}} + \mathbf{H}^T \mathbf{R}^{-1} \mathbf{Z} \quad (4.13)$$

$$\mathbf{P}^{-1} = \bar{\mathbf{P}}^{-1} + \mathbf{H}^T \mathbf{R}^{-1} \mathbf{H} \quad (4.14)$$

其中两传感器联合测量为

$$\mathbf{Z} = \begin{bmatrix} \mathbf{Z}_1 \\ \mathbf{Z}_2 \end{bmatrix} \quad \mathbf{H} = \begin{bmatrix} \mathbf{H}_1 \\ \mathbf{H}_2 \end{bmatrix} \quad \mathbf{R} = \begin{bmatrix} \mathbf{R}_1 & 0 \\ 0 & \mathbf{R}_2 \end{bmatrix} \quad (4.15)$$

由于

$$\mathbf{H}^T \mathbf{R}^{-1} \mathbf{Z} = \mathbf{H}_1^T \mathbf{R}_1^{-1} \mathbf{Z}_1 + \mathbf{H}_2^T \mathbf{R}_2^{-1} \mathbf{Z}_2 \quad (4.16)$$

$$\mathbf{H}^T \mathbf{R}^{-1} \mathbf{H} = \mathbf{H}_1^T \mathbf{R}_1^{-1} \mathbf{H}_1 + \mathbf{H}_2^T \mathbf{R}_2^{-1} \mathbf{H}_2 \quad (4.17)$$

于是式 (4.13)、式 (4.14) 变为

$$\mathbf{P}^{-1} \hat{\mathbf{x}} = \bar{\mathbf{P}}^{-1} \bar{\mathbf{x}} + \mathbf{H}_1^T \mathbf{R}_1^{-1} \mathbf{Z}_1 + \mathbf{H}_2^T \mathbf{R}_2^{-1} \mathbf{Z}_2 \quad (4.18)$$

$$\mathbf{P}^{-1} = \bar{\mathbf{P}}^{-1} + \mathbf{H}_1^T \mathbf{R}_1^{-1} \mathbf{H}_1 + \mathbf{H}_2^T \mathbf{R}_2^{-1} \mathbf{H}_2 \quad (4.19)$$

这就是文献[11]中所使用的信息融合方程, 用于融合各局部代理 (传感器) 传输来的测量。将式 (4.12) 中两式均对  $i=1,2$  相加, 并将式 (4.18) 和式 (4.19) 分别代入, 得到类似于式 (4.9)、式 (4.10) 的IMF方程如下:

$$\mathbf{P}^{-1} \hat{\mathbf{x}} = \mathbf{P}_1^{-1} \hat{\mathbf{x}}_1 + \mathbf{P}_2^{-1} \hat{\mathbf{x}}_2 - \bar{\mathbf{P}}^{-1} \bar{\mathbf{x}} \quad (4.20)$$

$$\mathbf{P}^{-1} = \mathbf{P}_1^{-1} + \mathbf{P}_2^{-1} - \bar{\mathbf{P}}^{-1} \quad (4.21)$$

其中  $\mathbf{x}$  的先验估计及其协方差  $\bar{\mathbf{x}}$  和  $\bar{\mathbf{P}}$  以两个局部估计中的共用信息形式出现, 并被去除掉。

信息矩阵融合 (IMF) 方法适用于无显著动态噪声或目标状态方程是确定的情况, 其中

要求每个局部估计都能以全速率传输到全局节点。IMF方程能够快速检测目标机动并建立机动后的状态方程。

## 2. 无反馈层次结构的贝叶斯分布融合算法

考虑图4.5 (b) 描绘的无反馈层次融合结构图。上层融合站点  $F_3$  接收下层站点  $F_2$  时间点  $L$  的估计  $p(x|Z_L)$  和  $F_3$  自身当前点  $H$  的 (先验) 估计  $P(x|Z_H)$ ，其中共用信息是从  $F_2$  时间点  $\bar{L}$  的最后传输来的估计  $p(x|Z_{\bar{L}})$ ，于是由式 (4.5) 可得上层站点  $F_3$  对这两个估计量的全局融合公式是

$$p(x|Z_H \cup Z_L) = C^{-1} \frac{p(x|Z_H)p(x|Z_L)}{p(x|Z_{\bar{L}})} \quad (4.22)$$

若随机变量各概率分布是高斯的，应用式 (4.9) 和式 (4.10)，得到

$$\mathbf{P}_{H \cup L}^{-1} = \mathbf{P}_H^{-1} + \mathbf{P}_L^{-1} - \mathbf{P}_{\bar{L}}^{-1} \quad (4.23)$$

$$\mathbf{P}_{H \cup L}^{-1} \hat{\mathbf{x}}_{H \cup L} = \mathbf{P}_H^{-1} \hat{\mathbf{x}}_H + \mathbf{P}_L^{-1} \hat{\mathbf{x}}_L - \mathbf{P}_{\bar{L}}^{-1} \hat{\mathbf{x}}_{\bar{L}} \quad (4.24)$$

从式 (4.23)、式 (4.24) 可以看出，在无反馈层次的贝叶斯融合中，全局代理在融合中对每个局部估计只使用一次，并且去掉了其中的共用信息。借助分布融合信息图，能够导出更复杂的多连接结构的贝叶斯分布融合方程，并识别出除全局融合需要的局部估计信息之外，还需要知晓的其他共用信息，如共用先验信息、共用过程噪声等。扩展到对多个局部估计和多个共用信息的全局融合也是比较容易的。

## 3. 有反馈层次结构的贝叶斯分布融合算法

对于如图 4.8 (b) 描绘的有反馈层次融合多连接信息图，可以看到全局融合可能在两个层次上出现。对于出现在低层  $F_1$  节点的全局融合，其输入的  $L_1$  点和  $H$  点估计的共用前辈节点是  $\bar{L}$ ，这是从低层向高层最后一次传输信息的节点。对于出现在高层  $F_3$  之  $H$  点的全局融合来说，其输入的  $F_2$  的  $L_2$  点估计和自身上一点  $H$  的先验估计的共用前辈节点是  $\bar{H}$ ，这是从高层向低层最后一次反馈传输信息的节点。于是出现在低层节点  $F_1$  的全局融合公式为

$$p(x|Z_H \cup Z_{L_1}) = C^{-1} \frac{p(x|Z_H)p(x|Z_{L_1})}{p(x|Z_{\bar{L}})} \quad (4.25)$$

类似地，出现在高层节点  $F_3$  之点  $H$  的全局融合公式为

$$p(x|Z_H \cup Z_{L_2}) = C^{-1} \frac{p(x|Z_H)p(x|Z_{L_2})}{p(x|Z_{\bar{H}})} \quad (4.26)$$

从该信息图中可以看到，若不考虑传输和处理时间延迟，出现在低层  $F_1$  的全局融合节点，在融合时三次使用了点  $\bar{L}$  的共用信息，而式 (4.25) 中只将  $\bar{L}$  点共用信息去除一次，这是由于考虑传输和处理时间延迟，经由  $\bar{L} - \bar{H} - L_2 - H$  路径的  $\bar{L}$  点信息尚未到达  $H$  点，因此  $H$  点的估计信息只使用一次（经由  $\bar{L} - \bar{H} - H$  路径到达  $H$  点的） $\bar{L}$  点信息。同样，式 (4.26) 也由于考虑时间延迟，仅将  $\bar{H}$  点共用信息去除一次。

若随机变量各概率分布是高斯的，低层全局融合方程是

$$\mathbf{P}_{H \cup L_1}^{-1} = \mathbf{P}_H^{-1} + \mathbf{P}_{L_1}^{-1} - \mathbf{P}_{\bar{L}}^{-1} \quad (4.27)$$

$$\mathbf{P}_{H \cup L_1}^{-1} \hat{\mathbf{x}}_{H \cup L_1} = \mathbf{P}_H^{-1} \hat{\mathbf{x}}_H + \mathbf{P}_{L_1}^{-1} \hat{\mathbf{x}}_{L_1} - \mathbf{P}_L^{-1} \hat{\mathbf{x}}_L \quad (4.28)$$

高层全局融合方程是

$$\mathbf{P}_{H \cup L_2}^{-1} = \mathbf{P}_H^{-1} + \mathbf{P}_{L_2}^{-1} - \mathbf{P}_{\bar{H}}^{-1} \quad (4.29)$$

$$\mathbf{P}_{H \cup L_2}^{-1} \hat{\mathbf{x}}_{H \cup L_2} = \mathbf{P}_H^{-1} \hat{\mathbf{x}}_H + \mathbf{P}_{L_2}^{-1} \hat{\mathbf{x}}_{L_2} - \mathbf{P}_{\bar{H}}^{-1} \hat{\mathbf{x}}_{\bar{H}} \quad (4.30)$$

#### 4. 任意结构的贝叶斯分布融合算法

任意分布结构的最优融合算法可以通过反复应用贝叶斯融合方程式(4.5)、式(4.6)得到。最优算法从识别进行融合的各信息节点的共用前辈节点开始,若仅存在一个共用前辈节点,其估计信息就成为式(4.5)分母中的 $p(\mathbf{x} | Z_1 \cap Z_2)$ ;若存在多个共用前辈节点,则利用每个共用节点信息计算目标的后验概率,并置于式(4.5)分母中。该过程反复进行,直到每个被融合估计中不包含共用前辈节点信息。这样一来,任意分布结构的通用融合方程就由各被融合信息的概率之积,除以要去除的共用冗余信息产生的目标后验概率,该通用融合形式如下<sup>[1,8]</sup>:

$$p\left(\mathbf{x} \middle| \bigcup_{i=1}^N Z_i\right) = C^{-1} \prod_{j \in J} p(\mathbf{x} | Z_j)^{\alpha(j)} \quad (4.31)$$

$$\alpha(j) = \begin{cases} 1 & j \in J_1 \\ -1 & j \in J_2 \end{cases} \quad (4.32)$$

其中 $J = J_1 + J_2$ 是全局融合节点的上游节点集合, $J_1$ 是该节点直接连接的输入信息节点集合, $J_2$ 是该全局融合节点的共用上游节点集合,这里只考虑最靠近全局融合节点的共用信息节点,不考虑形成共用节点的更上游共用节点,并且出于对信息传输和处理延迟的考虑,每个共用节点只重用一次,故每个共用信息只去除一次。

对于随机分布是高斯的情况,任意分布结构的全局通用融合方程是

$$\mathbf{P}^{-1} \hat{\mathbf{x}} = \sum_{j \in J} \alpha(j) \mathbf{P}_j^{-1} \hat{\mathbf{x}}_j \quad (4.33)$$

$$\mathbf{P}^{-1} = \sum_{j \in J} \alpha(j) \mathbf{P}_j^{-1} \quad (4.34)$$

前面几小节讨论的关于层次结构的融合方程是该通用融合方程的特殊情况。

从图4.16描绘的三节点循环分发结构的信息图可以看到,对于在节点 $F_1$ 的点 $A$ 处进行的全局融合,其直接连接的输入点是 $B$ 和 $C$ , $B$ 和 $C$ 的最近共用上游节点为 $D$ 和 $E$ ,即 $B$ 和 $C$ 的共用信息集合 $Z_{D \cup E}$ ,而 $D$ 和 $E$ 又具有共用上游节点 $F$ 和 $G$ ,即 $D$ 和 $E$ 的共用信息集合是 $Z_{F \cup G} = Z_H$ ,反复应用融合方程(4.31)和(4.32),可以产生下述等式:

$$\begin{aligned} p(\mathbf{x} | Z_A) &= C^{-1} \frac{p(\mathbf{x} | Z_B) p(\mathbf{x} | Z_C)}{p(\mathbf{x} | Z_{D \cup E})} \\ &= C^{-1} \frac{p(\mathbf{x} | Z_B) p(\mathbf{x} | Z_C) p(\mathbf{x} | Z_{F \cup G})}{p(\mathbf{x} | Z_D) p(\mathbf{x} | Z_E)} \\ &= C^{-1} \frac{p(\mathbf{x} | Z_B) p(\mathbf{x} | Z_C) p(\mathbf{x} | Z_H)}{p(\mathbf{x} | Z_D) p(\mathbf{x} | Z_E)} \end{aligned} \quad (4.35)$$

对于随机分布是高斯的情况,可以得到:

$$\mathbf{P}_A^{-1} \hat{\mathbf{x}}_A = \mathbf{P}_B^{-1} \hat{\mathbf{x}}_B + \mathbf{P}_C^{-1} \hat{\mathbf{x}}_C - \mathbf{P}_D^{-1} \hat{\mathbf{x}}_D - \mathbf{P}_E^{-1} \hat{\mathbf{x}}_E + \mathbf{P}_H^{-1} \hat{\mathbf{x}}_H \quad (4.36)$$



$$\mathbf{P}_A^{-1} = \mathbf{P}_B^{-1} + \mathbf{P}_C^{-1} - \mathbf{P}_D^{-1} - \mathbf{P}_E^{-1} + \mathbf{P}_H^{-1} \quad (4.37)$$

#### 4.4.4 次优贝叶斯分布融合算法

4.3.3 节所描述的各种最优贝叶斯分布融合算法需要利用信息图识别共用节点，以确定全局融合中采用的重复（冗余）信息和重用次数。当网络带宽不支持信息谱系传输时，如特定的无线传感器网络（WSN）情况，无法通过全局融合节点来构建信息图中的相应功能，因为全局融合节点所需输入信息无法及时到达。即使所需信息谱系能够传输，在一个采用容许失效或自适应通信策略的动态网络中，最优分布式融合算法也难以实现，这是由于为去除信息重用引起的相关性，需要很长的谱系信息。本节提出的几种实用的、可度量的算法<sup>[21]</sup>，是基于对最优算法（4.31）～（4.34）的近似实现的。在下面几种次优融合算法中，两个局部节点的融合结果仍采用概率函数  $p_1(x)$ 、 $p_2(x)$  或离散的  $\hat{x}_1$ 、 $\mathbf{P}_1$  与  $\hat{x}_2$ 、 $\mathbf{P}_2$ 。全局融合结果表示为  $p(x)$  或  $\hat{x}$  与  $\mathbf{P}$ 。

##### 1. 凸组合融合

凸组合融合又被称为自然融合（Naive Fusion, NF），该算法忽略输入的各局部估计之间存在重复使用共用信息产生的相关性，即忽略最优贝叶斯估计方程（4.5）中的分母，于是得凸组合算法可用下式描述：

$$p(x) = C^{-1} p_1(x) p_2(x) \quad (4.38)$$

式中， $C$  是规格化常数。对于高斯分布情况，在式（4.9）和式（4.10）中类似地忽略共用信息  $\hat{x}_{1\cap 2}$ 、 $\mathbf{P}_{1\cap 2}$ ，得到下述方程：

$$\begin{aligned} \mathbf{P}^{-1} &= \mathbf{P}_1^{-1} + \mathbf{P}_2^{-1} \\ \mathbf{P}^{-1} \hat{x} &= \mathbf{P}_1^{-1} \hat{x}_1 + \mathbf{P}_2^{-1} \hat{x}_2 \end{aligned} \quad (4.39)$$

或

$$\hat{x} = \mathbf{P}_2(\mathbf{P}_1 + \mathbf{P}_2)^{-1} \hat{x}_1 + \mathbf{P}_1(\mathbf{P}_1 + \mathbf{P}_2)^{-1} \hat{x}_2 \quad (4.40)$$

由于在信息矩阵  $\mathbf{P}^{-1}$  中未扣除共用信息矩阵  $\mathbf{P}_{1\cap 2}^{-1}$ ，因此凸组合产生的全局融合误差协方差小于实际的误差协方差，所得到的估计结果精度有时显得不可信。该算法简单，适应于良好条件下（单一目标、状态模型较准确）的目标航迹跟踪问题。

##### 2. 信道滤波融合算法

信道滤波融合算法将一个分布式融合估计系统视为由大量信道组成，每个信道由一对发一收节点来定义。在信道滤波算法中，一个下游节点的全局融合对所有上游节点的信息传输历程保持跟踪，在全局融合计算时只保留最近时间接收的上游共用节点的估计信息，作为各局部估计中的重用信息予以去除，而忽略对该共用信息有贡献的更早的共用信息节点。在这个意义上，信道滤波算法可以视为基于融合信息图的最优贝叶斯分布融合算法的一阶近似<sup>[12, 13, 33]</sup>。

具体地说，该信道滤波融合方程如下：

$$p(x) = C^{-1} \frac{p_1(x) p_2(x)}{\bar{p}(x)} \quad (4.41)$$

式中,  $C$  是一个规格化常数,  $\bar{p}(x)$  是从这两个信道接收的局部估计中所含有的最近时间共用节点信息 (概率函数), 是信道滤波公式中要去除的共用先验信息, 高斯分布情况  $\bar{p}(x)$  具有均值  $\bar{x}$  和协方差  $\bar{P}$ 。

若  $p_1(x)$  和  $p_2(x)$  是高斯的, 其均值和协方差分别为  $\bar{x}_1$ 、 $P_1$  和  $\bar{x}_2$ 、 $P_2$ , 则信道滤波公式为

$$P^{-1} = P_1^{-1} + P_2^{-1} - \bar{P}^{-1} \quad (4.42)$$

$$P^{-1}\hat{x} = P_1^{-1}\hat{x}_1 + P_2^{-1}\hat{x}_2 - \bar{P}^{-1}\bar{x} \quad (4.43)$$

由于没有考虑被融合的局部估计中所含有的更上游的共用信息, 故信道滤波融合算法是最优贝叶斯分布融合算法的一阶近似。但若所去除的共用节点信息估计出现在与当前全局融合估计时间较远上游, 该信道滤波融合算法接近最优。

对于图 4.16 描绘的三节点循环分发式融合机制, 在节点  $F_1$  的点  $A$  进行的信道滤波公式为

$$p(x|Z_A) = C^{-1} \frac{p(x|Z_B)p(x|Z_C)}{p(x|Z_D)} \quad (4.44)$$

其中忽略了该机制下最优贝叶斯融合方程 (4.35) 中的一些其他项, 仅考虑了  $B$  点和  $C$  点的一个最近共用节点  $D$  的信息, 并予以去除。类似地, 高斯分布情况的融合方程 (4.44) 变为

$$P_A^{-1}\hat{x}_A = P_B^{-1}\hat{x}_B + P_C^{-1}\hat{x}_C - P_D^{-1}\hat{x}_D \quad (4.45)$$

$$P_A^{-1} = P_B^{-1} + P_C^{-1} - P_D^{-1} \quad (4.46)$$

### 3. Chernoff 融合算法

Chernoff 信息融合与凸组合融合一样, 忽略被融合的局部估计之间的相关性, 但考虑两局部估计可能对全局融合所起的作用不同, 对被融合的全局估计概率函数采用不同的指数权重, 得到:

$$p(x) = C^{-1} p_1^w(x) p_2^{1-w}(x) \quad (4.47)$$

其中  $w \in [0, 1]$ , 可以通过对所选择的指标达极小获得。由于这里的极小化指标采用规格化常数  $C$  定义的 Chernoff 信息<sup>[34]</sup>, 故得此名。能够证明, 通过使 Chernoff 信息达极小, 从式 (4.47) 得到的融合概率函数是两个 Kullback Leibler 距离的初始密度之间的一个中间值<sup>[34]</sup>。若  $P_1(x)$  和  $P_2(x)$  是高斯的, 得到的全局融合密度也是高斯的, 其均值和协方差如下:

$$P^{-1} = wP_1^{-1} + (1-w)P_2^{-1} \quad (4.48)$$

$$P^{-1}\hat{x} = wP_1^{-1}\hat{x}_1 + (1-w)P_2^{-1}\hat{x}_2 \quad (4.49)$$

该公式与文献[13, 14, 20, 35, 36, 37]给出的协方差交集 (CI) 融合算法相同, 因此可以说 CI 融合算法是 Chernoff 融合算法的一种特殊情况。

Chernoff 融合算法可以用来组合对数线性形式的两个局部 (任意分布) 概率, 但所得到的全局融合概率可能与两个被融合概率具有不同的形式。此外, 该算法可能还需要为求取适宜的权重参数进行搜索和计算。

### 4. Bhattacharyya 融合算法

在式 (4.47) 中, 指数权重取  $w = 0.5$  时, Chernoff 融合变成

$$p(x) = B^{-1} \sqrt{p_1(x)p_2(x)} \quad (4.50)$$

其中规格化常数为  $B = \int \sqrt{p_1(x)p_2(x)} dx$ ，式 (4.50) 被称为 Bhattacharyya 融合。

若  $p_1(x)$ 、 $p_2(x)$  是高斯的，融合方程可写为

$$\begin{aligned} \mathbf{P}^{-1} &= \frac{1}{2}(\mathbf{P}_1^{-1} + \mathbf{P}_2^{-1}) \\ \mathbf{P}^{-1}\hat{\mathbf{x}} &= \frac{1}{2}(\mathbf{P}_1^{-1}\hat{\mathbf{x}}_1 + \mathbf{P}_2^{-1}\hat{\mathbf{x}}_2) \end{aligned} \quad (4.51)$$

或

$$\hat{\mathbf{x}} = (\mathbf{P}_1^{-1} + \mathbf{P}_2^{-1})^{-1}(\mathbf{P}_1^{-1}\hat{\mathbf{x}}_1 + \mathbf{P}_2^{-1}\hat{\mathbf{x}}_2) \quad (4.52)$$

这样，Bhattacharyya 融合类似于高斯情况的凸组合融合，但比较式 (4.51) 和式 (4.39) 可以看出，Bhattacharyya 融合误差协方差是凸组合的 2 倍。如果将式 (4.51) 中两式改写为

$$\mathbf{P}^{-1} = \frac{1}{2}(\mathbf{P}_1^{-1} + \mathbf{P}_2^{-1}) = (\mathbf{P}_1^{-1} + \mathbf{P}_2^{-1}) - \frac{1}{2}(\mathbf{P}_1^{-1} + \mathbf{P}_2^{-1}) \quad (4.53)$$

$$\begin{aligned} \mathbf{P}^{-1}\hat{\mathbf{x}} &= \frac{1}{2}(\mathbf{P}_1^{-1}\hat{\mathbf{x}}_1 + \mathbf{P}_2^{-1}\hat{\mathbf{x}}_2) \\ &= (\mathbf{P}_1^{-1}\hat{\mathbf{x}}_1 + \mathbf{P}_2^{-1}\hat{\mathbf{x}}_2) - \frac{1}{2}(\mathbf{P}_1^{-1}\hat{\mathbf{x}}_1 + \mathbf{P}_2^{-1}\hat{\mathbf{x}}_2) \end{aligned} \quad (4.54)$$

与信道滤波公式 (4.42)、(4.43) 比较，可以看出，这实际上是用两组融合输入信息的均值来代替信道滤波中要去除的来自前面通信产生的共用先验信息，即用  $\frac{1}{2}(\mathbf{P}_1^{-1} + \mathbf{P}_2^{-1})$  代替  $\bar{\mathbf{P}}^{-1}$ ，用  $\frac{1}{2}(\mathbf{P}_1^{-1}\hat{\mathbf{x}}_1 + \mathbf{P}_2^{-1}\hat{\mathbf{x}}_2)$  代替  $\bar{\mathbf{P}}^{-1}\bar{\mathbf{x}}$ 。或者说，Bhattacharyya 融合中要去除的共用信息采用被融合的两个局部估计的均值来近似。

#### 4.4.5 高斯分布或带有误差协方差估计的全局估计

在 4.4.4 节中，我们提出了几种次优算法，它们避开了利用信息图准确识别并去除冗余信息（共用信息）这一难点。这些算法可以视为基于通用的概率准则的最优融合算法的近似。本节给出融合输入信息是高斯的或者是能够采用带有误差协方差的估计来表示时，采用某些准则的最优融合算法。

本节假设被融合的两个局部估计是  $\hat{\mathbf{x}}_1$  和  $\hat{\mathbf{x}}_2$ ，误差协方差分别为  $\mathbf{P}_1$  和  $\mathbf{P}_2$ ，交叉协方差为  $\mathbf{P}_{12} = \mathbf{P}_{21}^T$ ，全局估计的共用先验信息为状态均值  $\bar{\mathbf{x}}$  及其协方差  $\bar{\mathbf{P}}$ 。

从分布式融合信息图可以看到，某节点全局估计中的共用信息来自上游其他共用节点或来自本节点的全局估计预测。从图 4.17 可以看出，全局估计的共用信息还来自两局部代理获得的对其 ROI 覆盖区内目标的测量。这三类共用信息使两局部估计之间产生较强的相关性。特别地，当两局部估计的信息来源（测量）不独立时，这两局部估计也存在较强的依赖性，即存在交叉协方差  $\mathbf{P}_{12} = \mathbf{P}_{21}^T$ 。这样一来，在全局融合时，仅去除信息图中展现的共用信息对于生成最优全局融合来说是不够的。

### 1. 极大后验融合和最优线性无偏估计

极大后验 (MAP) 融合既考虑了被融合的两局部估计中的共用信息, 又考虑了非独立 (相互依赖) 信息源产生的相关性。假设输入的两个局部估计即其协方差分别为  $\hat{\mathbf{x}}_1$ 、 $\mathbf{P}_1$  和  $\hat{\mathbf{x}}_2$ 、 $\mathbf{P}_2$ , 交叉协方差为  $\mathbf{P}_{12} = \mathbf{P}_{21}^T$ ;  $\hat{\mathbf{x}}_1$ 、 $\hat{\mathbf{x}}_2$  与状态  $\mathbf{x}$  的交叉协方差为  $\mathbf{P}_{01}$ 、 $\mathbf{P}_{02}$ ; 并且共用先验信息  $\bar{\mathbf{x}}$ 、 $\bar{\mathbf{P}}$  已知。

令  $\mathbf{z} = [\hat{\mathbf{x}}_1^T, \hat{\mathbf{x}}_2^T]^T$  作为全局融合输入的测量增广向量。假设  $\mathbf{z}$  与  $\mathbf{x}$  是联合高斯分布, 具有均值  $\bar{\mathbf{z}}$  和  $\bar{\mathbf{x}}$ , 协方差是:

$$\mathbf{P}_{xz} = \mathbf{P}_{zx}^T \triangleq E[(\mathbf{x} - \bar{\mathbf{x}})(\mathbf{z} - \bar{\mathbf{z}})^T] = [\mathbf{P}_{01}, \mathbf{P}_{02}] \quad (4.55)$$

$$\mathbf{P}_{zz} \triangleq E[(\mathbf{z} - \bar{\mathbf{z}})(\mathbf{z} - \bar{\mathbf{z}})^T] = \begin{bmatrix} \mathbf{P}_1 & \mathbf{P}_{12} \\ \mathbf{P}_{21} & \mathbf{P}_2 \end{bmatrix} \quad (4.56)$$

给出输入的测量增广向量  $\mathbf{z}$ , 则全局融合状态  $\mathbf{x}$  的后验分布  $p(\mathbf{x}|\mathbf{y})$  也是高斯分布, 且具有如下均值和协方差<sup>[38]</sup>:

$$\hat{\mathbf{x}} = \bar{\mathbf{x}} + \mathbf{P}_{xz} \mathbf{P}_{zz}^{-1} (\mathbf{z} - \bar{\mathbf{z}}) \quad (4.57)$$

$$\mathbf{P} = \bar{\mathbf{P}} - \mathbf{P}_{xz} \mathbf{P}_{zz}^{-1} \mathbf{P}_{zx} \quad (4.58)$$

此式就是状态  $\mathbf{x}$  的一个极大后验 (MAP) 估计<sup>[18, 19]</sup>, 并可以表示为

$$\mathbf{x} = \bar{\mathbf{x}} + \mathbf{W}_1 (\hat{\mathbf{x}}_1 - \bar{\mathbf{x}}) + \mathbf{W}_2 (\hat{\mathbf{x}}_2 - \bar{\mathbf{x}}) = \mathbf{W}_0 \bar{\mathbf{x}} + \mathbf{W}_1 \hat{\mathbf{x}}_1 + \mathbf{W}_2 \hat{\mathbf{x}}_2 \quad (4.59)$$

其中  $\mathbf{W}_1, \mathbf{W}_2$  为

$$[\mathbf{W}_1, \mathbf{W}_2] = \mathbf{P}_{xz} \mathbf{P}_{zz}^{-1} = [\mathbf{P}_{01} \quad \mathbf{P}_{02}] \begin{bmatrix} \mathbf{P}_1 & \mathbf{P}_{12} \\ \mathbf{P}_{21} & \mathbf{P}_2 \end{bmatrix}^{-1} \quad (4.60)$$

这里  $\mathbf{W}_0 = \mathbf{I} - \mathbf{W}_1 - \mathbf{W}_2$ ,  $\mathbf{P}_{0i} = E[(\mathbf{x} - \bar{\mathbf{x}})(\hat{\mathbf{x}}_i - \bar{\mathbf{x}})^T]$  ( $i=1, 2$ ), 如式 (4.55) 所示。

如果  $\hat{\mathbf{x}}_1$  和  $\hat{\mathbf{x}}_2$  不是联合高斯分布, 而是瞬时已知的, 则式 (4.59) 是状态  $\mathbf{x}$  的最优线性无偏估计 (BLUE)<sup>[16, 17]</sup>。我们注意到, 该 MAP 估计或 BLUE 在计算时需要较多信息, 除了共用先验信息  $\bar{\mathbf{x}}$ 、 $\bar{\mathbf{P}}$ , 以及带有估计误差协方差  $\mathbf{P}_1$ 、 $\mathbf{P}_2$  的局部估计  $\hat{\mathbf{x}}_1$ 、 $\hat{\mathbf{x}}_2$  之外, 还需要知道这两个局部估计之间的交叉协方差  $\mathbf{P}_{12} = \mathbf{P}_{21}^T$ , 以及这两个估计与状态  $\mathbf{x}$  之间的交叉协方差  $\mathbf{P}_{01}$  与  $\mathbf{P}_{02}$ 。 $\mathbf{P}_{12}$ 、 $\mathbf{P}_{01}$ 、 $\mathbf{P}_{02}$  的详细表达式及推导见第 6 章。

如果  $\hat{\mathbf{x}}_1$  和  $\hat{\mathbf{x}}_2$  是由带有独立误差的测量生成的, 则式 (4.59)、式 (4.60) 可简化为传统独立高斯随机向量的信息矩阵融合 (IMF) 方程 (4.20)、(4.21)。

极大后验融合适用于被融合的另一目标的两条局部航迹带有显著偏差情况, 如目标机动或强干扰环境。当通信带宽无法保证将局部估计及时传送到全局融合节点时, MAP 融合只能达到次优效果。

### 2. 交叉协方差融合

交叉协方差 (Cross Corariance) 融合规则直接考虑两局部估计的交叉协方差, 而不考虑共用先验信息<sup>[15]</sup>, 该融合规则如下:

$$\hat{\mathbf{x}} = \mathbf{W}_1 \hat{\mathbf{x}}_1 + \mathbf{W}_2 \hat{\mathbf{x}}_2 \quad (4.61)$$

其中

$$\begin{aligned} W_1 &= (P_2 - P_{21})(P_1 + P_2 - P_{12} - P_{21})^{-1} \\ W_2 &= (P_1 - P_{12})(P_1 + P_2 - P_{12} - P_{21})^{-1} \end{aligned} \quad (4.62)$$

注意  $W_1 + W_2 = I$ ，若被融合的两个局部估计是无偏的，则全局融合估计也是无偏的。

式 (4.61) 和式 (4.62) 所示的融合规则可视为使经典似然函数  $p(\hat{x}_1, \hat{x}_2 | x)$  达极大来获得  $x$  的估计。这样交叉协方差融合规则也可视为极大似然融合规则。方程 (4.61) 是不考虑共用先验信息的 BLUE 的唯一解，即没有利用先验信息（初始条件）所获得的线性解<sup>[39]</sup>，该结论也可以从先验协方差变得很大时，极大后验（MAP）估计变成极大似然估计得到。

如果忽略交叉协方差项  $P_{12}$  和  $P_{21}$ ，则式 (4.62) 变成

$$\begin{aligned} W_1 &= P_2(P_1 + P_2)^{-1} = (P_1^{-1} + P_2^{-1})P_2^{-1} \\ W_2 &= P_1(P_1 + P_2)^{-1} = (P_1^{-1} + P_2^{-1})P_1^{-1} \end{aligned} \quad (4.63)$$

这就是从两个独立的局部估计  $\hat{x}_1$ 、 $\hat{x}_2$  及其协方差  $P_1$ 、 $P_2$  得到的全局融合规则。将式 (4.63) 中的  $W_1$  和  $W_2$  代入式 (4.61)，我们就可以得到凸组合公式。

我们注意到，表示全局融合误差的尺寸之一是两局部估计的估计误差协方差矩阵的行列式：

$$\begin{bmatrix} P_1 & P_{12} \\ P_{21} & P_2 \end{bmatrix} = \det(P_1 - P_{12}P_2^{-1}P_{21})\det(P_2)$$

若忽略交叉协方差  $P_{12} = P_{21}^T = 0$ ，则两局部估计的联合协方差矩阵确定的误差椭圆会增大。于是，简化的融合规则式 (4.63) 及其产生的凸组合融合公式可以通过增大联合估计误差协方差矩阵获得。

交叉协方差融合适用于已知目标存在，仅需确定跟踪参数且杂波较低的情况。

## 4.5 目标跟踪中的分布式估计

我们在这里讨论支持目标跟踪的分布式估计的通用方法<sup>[40, 41]</sup>。多目标分布式跟踪技术包含多传感器测量关联以融合生成目标局部航迹，以及基于局部航迹融合估计和预测全局目标航迹的状态。在本节重点讨论第二个问题，对形成局部航迹的目标状态进行全局融合估计。多对象全局分布式跟踪中的关联问题在第 6 章中讨论。

### 4.5.1 问题描述

在分布式目标跟踪中，目标状态通常是一个随机过程，其动态模型由状态转移概率  $p(x_k | x_{k-1})$  给出，其中  $x_k$  是  $t_k$  时刻的目标状态。测量模型由传感器测量的条件概率密度即条件似然函数  $p(z_k | x_k)$  给出，是基于状态产生的测量条件分布。在目标跟踪中，通常采用递推估计逐周期进行，从  $t_{k-1}$  到  $t_k$  的递推贝叶斯估计过程如图 4.19 所示。

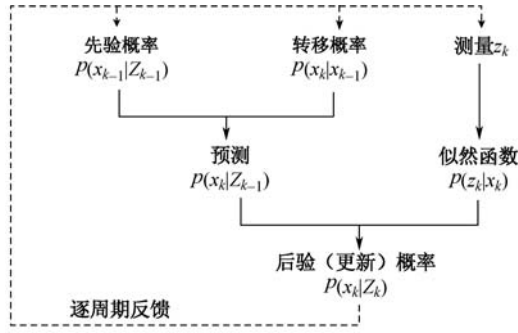


图 4.19 递推贝叶斯估计过程

图 4.19 中,  $Z_k = (z_1, z_2, \dots, z_k)$  是直到  $k$  周期的累积测量。从图 4.19 可以看出, 在每个递推估计周期中, 贝叶斯估计都包含两个步骤: 预测与更新。预测是指从先验概率 (指  $k-1$  周期的状态估计, 视为  $k$  周期状态估计的先验值)  $p(x_{k-1}|Z_{k-1})$  产生本周期预测概率  $p(x_k|Z_{k-1})$ ; 更新是指基于预测概率并利用本周期测量  $z_k$  更新生成本周期后验概率  $p(x_k|Z_k)$ 。由于预测步骤仅利用目标的动态模型 (转移概率), 并不依赖于测量, 故我们只看重更新步骤, 而将预测步骤分为动态模型是确定性和非确定性两种情况。

在分布式目标跟踪中, 我们对递推贝叶斯估计的每一周期, 都采用层次融合结构。设两个低层融合站点基于其局部观测生成的目标状态估计为  $p(x_k|Z_{ik})$ , 这里  $Z_{ik} = (z_{i1}, z_{i2}, \dots, z_{ik})$   $i=1, 2$ 。于是问题归结为高层站点 (代理) 如何组合这两个局部估计以生成目标状态的全局融合更新估计  $p(x_k|Z_k)$ , 这里  $Z_k = Z_{1k} \cup Z_{2k}$ 。

### 4.5.2 确定性动态过程

一个运动目标的未来状态若完全由其当前状态所确定, 即目标状态方程不含过程噪声, 则将该目标状态视为一个确定性动态过程。例如, 弹道导弹和空间目标就是具有确定性动态的例子, 因为他们按预定的精确轨道运行。不难看出, 对于确定性动态过程, 在给出目标状态  $x_k$  的条件下, 每个传感器测量  $z_{ik}$  对所有  $i$  和  $k$  具有条件独立性, 即给出  $x_k$  条件下的累计测量  $z_{ik}$  相互独立:

$$p(Z_{1k}, Z_{2k} | x_k) = p(Z_{1k} | x_k) p(Z_{2k} | x_k) \quad (4.64)$$

于是采用贝叶斯公式可获得全局融合估计如下:

$$p(x_k | Z_{1k}, Z_{2k}) = C^{-1} \frac{p(x_k | Z_{1k}) p(x_k | Z_{2k})}{p(x_k | Z_{k-1})} \quad (4.65)$$

式中,  $C$  是归一化常数。式 (4.65) 仅将两局部融合估计作为全局融合输入, 而  $p(x_k | Z_{k-1})$  是全局节点提供的预测信息, 作为两局部融合节点的共用先验信息在全局融合中予以去除一次。若随机变量是高斯分布, 该全局融合估计为

$$P_{k|k}^{-1} \hat{x}_{k|k} = P_{1,k|k}^{-1} \hat{x}_{1,k|k} + P_{2,k|k}^{-1} \hat{x}_{2,k|k} - P_{k|k-1}^{-1} \hat{x}_{k|k-1} \quad (4.66)$$

$$P_{k|k}^{-1} = P_{1,k|k}^{-1} + P_{2,k|k}^{-1} - P_{k|k-1}^{-1} \quad (4.67)$$

如果两个局部节点不使用全局节点的预测信息作为共用先验信息, 只使用自身节点的预测信息, 在全局融合时要将两局部节点的预测信息分别作为相应的共用先验信息予以去除, 并且将全局节点的预测信息 (其与全局节点当前状态信息相互独立) 作为全局融合输入参

与融合，这样得到全局融合估计如下：

$$p(x_k | Z_{1k}, Z_{2k}) = C^{-1} \frac{p(x_k | Z_{1k}) p(x_k | Z_{2k})}{p(x_k | Z_{1,k-1}) p(x_k | Z_{2,k-1})} p(x_k | Z_{k-1}) \quad (4.68)$$

若随机变量是高斯分布，该全局融合估计为

$$\mathbf{P}_{k|k}^{-1} \hat{\mathbf{x}}_{k|k} = \mathbf{P}_{1,k|k}^{-1} \hat{\mathbf{x}}_{1,k|k} - \mathbf{P}_{1,k|k}^{-1} \hat{\mathbf{x}}_{1,k|k-1} + \mathbf{P}_{2,k|k}^{-1} \hat{\mathbf{x}}_{2,k|k} - \mathbf{P}_{2,k|k-1}^{-1} \hat{\mathbf{x}}_{2,k|k-1} + \mathbf{P}_{k|k-1}^{-1} \hat{\mathbf{x}}_{k|k-1} \quad (4.69)$$

$$\mathbf{P}_{k|k}^{-1} = \mathbf{P}_{1,k|k}^{-1} - \mathbf{P}_{1,k|k-1}^{-1} + \mathbf{P}_{2,k|k}^{-1} - \mathbf{P}_{2,k|k-1}^{-1} + \mathbf{P}_{k|k-1}^{-1} \quad (4.70)$$

### 4.5.3 非确定性动态过程

当运动目标是非确定性动态过程，该目标的未来状态不仅依赖于它的当前状态，还依赖于该目标的共用动态噪声，这破坏了各时刻状态的独立性。此时同一传感器累积的测量  $\mathbf{Z}_{ik}$  ( $i=1,2$ ) 在给出  $\mathbf{x}_k$  的情况下不再是相互独立的，即式 (4.64) 不成立。同时，两个低层代理在每次观测后都要向高层代理报知局部融合结果（在有反馈情况，每次全局融合后高层融合估计都要向低层传送），否则不确定性动态过程的全局融合估计将不是最优的，但这样做会产生巨大的通信与计算负荷。下面介绍两种非确定性动态目标跟踪中的分布式估计方法。

#### (1) 扩展状态向量近似方法

定义  $\mathbf{X}_1 = [\mathbf{x}_1^T, \mathbf{x}_2^T, \dots, \mathbf{x}_m^T]^T$  是由多个观测时刻目标状态组成的扩展状态向量，类似地，定义  $\mathbf{X}_2 = [\mathbf{x}_{m+1}^T, \mathbf{x}_{m+2}^T, \dots, \mathbf{x}_{2m}^T]^T$ ，其中  $m$  值的选择要使扩展状态向量  $\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_k$  成为确定性动态过程，即在给出  $\mathbf{X}_k$  的情况下，其对应的扩展测量向量  $\mathbf{Z}_{ik}$  之间是条件独立的，这可以通过将每个扩展状态向量各分量之间的共用过程噪声转换为交叉协方差来实现。此时用  $\mathbf{X}_k$  取代式 (4.64) ~ 式 (4.70) 中的  $\mathbf{x}_k$ ，就得到关于扩展状态向量的非确定性动态全局最优融合估计方程。然而，由于扩展状态  $\mathbf{X}_k$  的概率密度或协方差矩阵具有较高维数，会产生很大的计算负荷，因此该方法在应用上并不现实。

#### (2) 使用单一时间交叉协方差的融合方法

对于由高斯随机向量或用均值和协方差表示的随机向量的分布式估计问题，4.4.5 节给出的融合估计方法能够用于处理非确定性动态过程产生的各测量之间的条件依赖性，此时的全局融合规则描述如下：

设  $\hat{\mathbf{x}}_{1,k|k}$  和  $\hat{\mathbf{x}}_{2,k|k}$  是要被融合的局部估计，带有误差协方差  $\mathbf{P}_{1,k|k}$ 、 $\mathbf{P}_{2,k|k}$  和交叉协方差  $\mathbf{P}_{12,k|k} = \mathbf{P}_{21,k|k}^T$ ；此外，被融合的还有共用先验估计，即  $\hat{\mathbf{x}}_{1,k|k-1}$  及其协方差为  $\mathbf{P}_{k|k-1}$ 。

于是，可用上述已知量分别代替 4.4.5 节各融合公式中的  $\hat{\mathbf{x}}_1$ 、 $\hat{\mathbf{x}}_2$ 、 $\mathbf{P}_1$ 、 $\mathbf{P}_2$ 、 $\mathbf{P}_{12}$ 、 $\bar{\mathbf{x}}$  和  $\bar{\mathbf{P}}$ ，应用 4.4.5 节中的极大后验 (MAP) 估计、最佳线性无偏估计 (BLUE) 或交叉协方差 (CC) 融合规则，即可实现非确定动态目标跟踪中的全局融合估计。本书第 6 章对非确定性动态目标跟踪的各类融合准则进行了比较。

## 4.6 对象分类识别的分布式估计

4.4.2 节描述的贝叶斯分布估计中重复计入信息的去除原理和 4.4.3 节给出的最优贝叶斯

分布融合估计方法同样适用于分布式对象的识别分类<sup>[42]</sup>,其中关注的识别状态是表示对象分类的一个离散的恒定随机向量。在对象识别状态测量相互独立的假设下,最优分布式对象识别分类可利用式(4.5)实现。然而,对象识别状态的观测通常不满足条件独立性假设,因为含有识别状态信息的测量也可能依赖于其他变量,如测量视角。我们在这里仅考虑单一时刻的层次融合识别,重点关注融合估计中使用的信息。许多复杂的通信模式需要检测共用信息并予以去除,必要时也可采用近似估计算法。本书第7章对分布式对象识别分类进行了更深入的讨论。

#### 4.6.1 对象分类的分布式识别结构

对象分类的通用融合识别结构通常有3种,即集中式测量融合识别结构,判定融合识别结构及不确定性融合识别结构。集中式测量融合识别结构将所有含有对象分类信息的测量传送到中心站点进行全局融合识别。该结构在理论上是最优的,因为此时中心站点能访问所有测量而不损失任何有用信息,但需要付出最大的通信代价。在判定融合识别结构中,每个传感器站点采用自身局部测量进行对象识别分类,并将其局部判定结果传送给融合中心站点进行全局融合识别,该结构仅需很少的通信带宽,但局部站点的判定结果会损失有效测量信息,使中心站点所进行的全局融合识别包含的信息不充分,产生较大的识别偏差。不确定性融合识别结构又被称为概率融合识别,其中每个低层站点产生一个基于来自自身局部测量的对象识别分类及其条件概率,传送给高层融合站点对这些条件概率进行组合,以形成全局识别分类及其条件概率。本章重点讨论概率融合识别方法。

建立高性能的概率融合识别方法的关键在于确定该概率所对应的分类状态。文献[43]第4章中给出了作战识别(CID)结构,其中将对象属性划分为多个识别级别,如信号识别级、自然属性识别级、身份属性识别级,每一级又由多个属性层次集合构成,如自然属性识别级包含空间类别、平台类别、型号类别等属性层次集合。在作战应用中,通常需要识别对象的多级别多层次属性分类状态。另一方面,对于某一级别或层次的属性分类(如自然属性中的型号、身份属性中的敌/我)通常并不能直接观测到,只能通过观测到的一些属性特征反映出来。与此同时,观测到的某一属性特征又有可能反映该对象的多个属性类别<sup>[27]</sup>。对于最优分布式融合估计来说,通常要求被融合的局部状态测量对属性状态或特征是条件独立的,因此对于实现对象的最优概率融合识别方法来说,全局概率融合自然要求各局部识别状态的测量之间是条件独立的。图4.20给出了一个关于对象分类识别的贝叶斯网络。

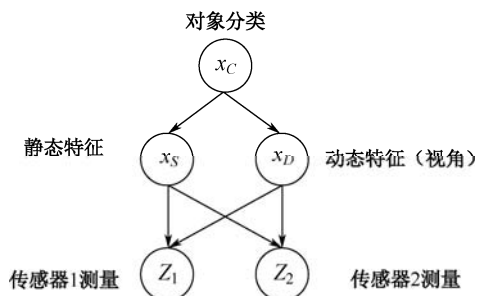


图4.20 关于对象分类识别的贝叶斯网络



图 4.20 中,  $Z_1$ 、 $Z_2$  表示对该对象分类的测量,  $x_c$  表示该对象的属性分类, 如型号层的某一型号类别, 通常目标型号不能直接观测到, 需依靠不同传感器测量的属性特征提供支持, 而在选择传感器时, 需要考虑其测量基于识别特征的条件独立性。这里所选择的传感器可观测的属性特征是目标的静态尺寸  $x_s$ , 以及目标相对于传感器的姿态角  $x_D$  (又称观测视角, 随传感器与目标运动状态的相对观测角度变化)。

我们注意到, 假设支持目标型号分类识别的  $x_s$  和  $x_D$  分别表示型号分类的静态和动态特征, 并且两传感器可独立对其进行测量, 于是  $Z_1$  和  $Z_2$  关于  $x_s$  和  $x_D$  是条件独立的:

$$p(Z_1, Z_2 | x_s, x_D) = p(Z_1 | x_s, x_D) p(Z_2 | x_s, x_D) \quad (4.71)$$

如果两传感器直接测量并估计目标型号分类  $x_c$ , 并且两个传感器测量关于  $x_c$  不是条件独立的, 于是

$$\begin{aligned} p(Z_1, Z_2 | x_c) &= \int p(Z_1, Z_2, x_s, x_D | x_c) dx_s dx_D \\ &= \int p(Z_1, Z_2 | x_s, x_D) p(x_s, x_D | x_c) dx_s dx_D \neq p(Z_1 | x_c) p(Z_2 | x_c) \end{aligned} \quad (4.72)$$

因此, 必须在传感器和目标型号分类  $x_c$  之间选择中间特征  $x_s$  和  $x_D$ , 并且基于这两个特征的两传感器测量具有条件独立性, 融合中心才能基于对这两个特征的局部估计实现对该对象分类  $x_c$  的全局最优估计。

#### 4.6.2 对象分类的分布式识别算法

在各局部节点传感器测量关于其识别命题条件独立的假设下, 若图 4.20 中的两局部融合节点基于其自身传感器测量  $Z_1$  和  $Z_2$  分别识别出静态属性特征  $x_s$  和动态属性特征  $x_D$ , 其联合状态特征  $(x_s, x_D)$  的后验概率密度函数分别为  $p(x_s, x_D | Z_1)$  和  $p(x_s, x_D | Z_2)$ 。于是全局融合节点对联合状态  $(x_s, x_D)$  的最优融合识别方程为

$$p(x_s, x_D | Z_1, Z_2) = C^{-1} \frac{p(x_s, x_D | Z_1) p(x_s, x_D | Z_2)}{p(x_s, x_D)} \quad (4.73)$$

其中将两局部识别的联合状态  $(x_s, x_D)$  的先验概率作为共用信息予以去除。

如果假设目标分类  $x_c$  能够基于其属性特征  $x_s$  和  $x_D$  确定, 即已知  $x_c$  的条件概率密度  $p(x_c | x_s, x_D)$ , 则可以进一步得到全局融合节点对目标分类  $x_c$  的后验分布概率

$$p(x_c | Z_1, Z_2) = \int p(x_c | x_s, x_D) p(x_s, x_D | Z_1, Z_2) dx_s dx_D \quad (4.74)$$

如果不考虑使测量  $Z_1$ 、 $Z_2$  条件独立的中间状态  $x_s$  和  $x_D$ , 并且忽略两局部传感器测量之间的相关性, 此时假设局部节点直接基于自身测量识别出的分类  $x_c$  的后验概率分别为  $p(x_c | Z_1)$  和  $p(x_c | Z_2)$ , 并将它们传递到全局节点, 全局节点可采用凸组合融合公式 (4.38) 得到分类  $x_c$  的近似识别结果:

$$p(x_c | Z_1, Z_2) = C^{-1} p(x_c | Z_1) p(x_c | Z_2) \quad (4.75)$$

值得注意的是, 这里所忽略的信息并不是由于传输产生的共用先验信息, 而是忽略了产生测量条件独立的状态和特征。

## 4.7 本章小结

本章给出了分布式融合系统的结构及可能采取的融合算法,它们构成了分布式融合估计的基础。分布式融合结构始于各离散融合站点的可能网络连接方式及可能出现的信息流程——信息图。在本章中,信息图既是选择一个适宜的融合结构的基础,又成为各融合节点选择优化算法的依据。本章没有介绍第3章所描述的分布式融合系统中各类节点(包括传感器节点、融合节点,以及应用节点)之间的协同算法,而是描述基于信息图如何避免信息重复使用,以及去除信息重复使用产生的相关性和各类节点所应采用的优化估计算法。重点提出了组合局部概率函数的贝叶斯全局融合方程及对局部均值和协方差表示的两个估计的组合方程。利用信息图,从贝叶斯融合方程能够导出适用于各种融合结构的融合方程。鉴于贝叶斯融合方程在实现上的复杂性(需要复杂结构的信息谱系和网络信息),本章还给出了实际应用中所采用的次优估计算法来逼近最优算法。当被融合的多个局部估计是高斯分布或能够用均值和协方差表示时,本章给出了几个线性组合准则,如极大后验融合、最优线性无偏估计,以及交叉协方差融合估计准则。本章最后还给出了分布式对象跟踪和对象分类识别概念和估计方法。

本章首次向读者展现了分布式融合系统中信息重复使用产生的信息相关性及信息重用来源:

- ① 信息图中展现的上游共用节点信息,为下游融合节点多次重复使用,是由多路径传输产生的;
- ② 多个融合节点重叠的关注区域中目标的测量要分发给相应的多个融合节点,从而在下游节点融合时产生该目标信息的重复使用;
- ③ 共用先验信息,指全局融合节点或局部节点的上游融合信息的预测结果,被作为下游融合的共用先验信息,产生信息重复使用;
- ④ 各传感器测量之间的非统计独立性(相关性)可视为由共用过程噪声引起的,可转换为融合误差中的交叉协方差以解除相关性。

## 参考文献

- [1] Chong C Y, S Mori, K C Chang. Distributed multitarget multisensor tracking. In Multitarget Multi-Sensor Tracking: Advanced Applications, Norwood, MA: Artech House, 1990, 247–295.
- [2] Liggins M E, K C Chang. Distributed fusion architectures, algorithms, and performance within a network-centric architecture. In Handbook of Multisensor Data Fusion: Theory and Practice, 2009.
- [3] Chong C Y. Hierarchical estimation. In Proceedings of MIT/ONR Workshop on C3, Monterey, CA, 1979.
- [4] Speyer J L. Computation and transmission requirements for a decentralized linearquadratic-Gaussian control problem. IEEE Transactions on Automatic Control, 1979, 24: 266–269.
- [5] Willsky A, M Bello, D Castanon, et al. Combining and updating of local estimates along sets of

- one-dimensional tracks. *IEEE Transactions on Automatic Control*, 1982, 27: 799–813.
- [6] Chong C Y, K C Chang, S Mori. Distributed tracking in distributed sensor networks. In *Proceedings of 1986 American Control Conference*, Seattle, WA, 1986.
- [7] Chong C Y, S Mori, K C Chang. Information fusion in distributed sensor networks. In *Proceedings of 1985 American Control Conference*, Boston, MA, 1985.
- [8] Chong C Y, S Mori, K C Chang. Adaptive distributed estimation. In *Proceedings of 26th IEEE Conference on Decision and Control*, Los Angeles, CA, 1987.
- [9] Chong C Y, E Tse, S Mori. Distributed estimation in networks. In *Proceedings of 1983 American Control Conference*, San Francisco, CA, 1983.
- [10] Chong C Y, S Mori, E Tse, et al. Distributed estimation in distributed sensor networks. In *Proceedings of 1982 American Control Conference*, Arlington, VA, 1982.
- [11] Durrant-Whyte H F, B S Y Rao, H Hu. Toward a fully decentralized architecture for multi-sensor data fusion. In *Proceedings of 1990 IEEE International Conference on Robotics and Automation*, Cincinnati, OH, 1990.
- [12] Grime S, H Durrant, Whyte. *Communication in decentralized systems*. In *IFAC Control Engineering Practice*. Oxford, U.K.: Pergamon Press, 1994.
- [13] Nicholson D, S J Julier, J K Uhlmann. DDF: An evaluation of covariance intersection. In *Proceedings of the 4th International Conference on Information Fusion*, Montreal, Quebec, Canada, 2001.
- [14] Nicholson D, C M Lloyd, S J Julier, et al. Scalable distributed data fusion. In *Proceedings of the 5th International Conference on Information Fusion*, Annapolis, MD, 2002.
- [15] Bar-Shalom Y, L Campo. The effects of the common process noise on the two-sensor fused-track covariance. *IEEE Transactions on Aerospace and Electronic Systems*, 1986, 22: 803–805.
- [16] Zhu Y, X R Li. Best linear unbiased estimation fusion. In *Proceedings of the 2nd International Conference on Information Fusion*, Sunnyvale, CA, 1999.
- [17] Li X, R Y Zhu, J Wang, et al. Optimal linear estimation fusion—Part I: Unified fusion rules. *IEEE Transactions on Information Theory*, 2003, 49: 2192–2208.
- [18] Mori S, W H Barker, C Y Chong, et al. Track association and track fusion with non-deterministic target dynamics. *IEEE Transactions on Aerospace and Electronic Systems*, 2002, 38: 659–668.
- [19] Chang K C, T Zhi, S Mori, et al. Performance evaluation for MAP state estimate fusion. *IEEE Transactions on Aerospace and Electronic Systems*, 2004, 40: 706–714.
- [20] Chong C Y, S Mori. Convex combination and covariance intersection algorithms in distributed fusion. In *Proceedings of the 4th International Conference on Information Fusion*, Montreal, Quebec, Canada, 2001.
- [21] Chang K C, C Y Chong, S Mori. Analytical and computational evaluation of scalable fusion algorithms. *IEEE Transactions on Aerospace and Electronic Systems*, 2010, 46: 2022–2034.
- [22] Chang K C, Saha R, Bar-Shalom Y, et al. Performance evaluation of multisensor track-to-track fusion, in *Proceedings of the 1996 IEEE/RSJ International Conference on Multisensor Fusion and Integration for Intelligent Systems*. 1996, 627–631.
- [23] Chang K C, Tian Z, Saha R. Performance evaluation for track fusion with information fusion, in *Proceedings*

- First International Conference on Multisource Multisensor Information Fusion'98, Las Vegas, July, 1998, 648–654.
- [24] Chang K C. Evaluating hierarchical track fusion with information matrix filter. in Proceedings of the Third International Society of Information Fusion, Paris, France, 13 July, 2000, Vol.1(10).
- [25] Chang K C, Mori S, Tian Z, et al. Map track fusion performance evaluation, in Proceedings of the Fifth International Society of Information Fusion, Annapolis, Vol. 1, 512–519, July 2002.
- [26] Chong C Y. Distributed architectures for data fusion. In Proceedings of the 1st International Conference on Multisource Multisensor Information Fusion, Las Vegas, NV, 1998.
- [27] Chong C Y, S Mori. Graphical models for nonlinear distributed estimation. In Proceedings of the 7th International Conference on Information Fusion, Stockholm, Sweden, 2004.
- [28] McLaughlin S P, R J Evans, V Krishnamurthy. A graph theoretic approach to data incest management in network centric warfare. In Proceedings of the 8th International Conference on Information Fusion, Philadelphia, PA, 2005.
- [29] McLaughlin S P, V Krishnamurthy, R J Evans. Bayesian network model for data incest in a distributed sensor network. In Proceedings of the 7th International Conference on Information Fusion, Stockholm, Sweden, 2004.
- [30] Brendan P R, Michael P. The US Navy presents its battle plan for network-centric warfare. The Journal of Electronic Defence, 2011.
- [31] 梁炎, 张仁茹, 董岩. 美国海军网络中心战浅析. 舰船电子工程, 2005, 25(3): 22–25.
- [32] 张修社. 海军协同作战体系结构韦国强译美国海军协同作战能力(CEC)文集. 中国电科集团第 20 研究所, 2001, 11.
- [33] Bourgault F, H F, Durrant-Whyte. Communication in general decentralized filter and the coordinated search strategy. In Proceedings of the 7th International Conference on Information Fusion, Stockholm, Sweden, 2004.
- [34] Cover T M, J A Thomas. Elements of Information Theory. New York: Wiley, 1991.
- [35] Hurley M. An information-theoretic justification for covariance intersection and its eneralization. In Proceedings of the 5th International Conference on Information Fusion, Annapolis, MD, 2002.
- [36] Julier S J. An empirical study into the use of Chernoff information for robust, distributed fusion of Gaussian mixture models. In Proceedings of the 9th International Conference on Information Fusion, Florence, Italy, 2006.
- [37] Julier S J, J K Uhlmann, J Walters, et al. The challenge of scalable and distributed fusion of disparate sources of information. In Proceedings of SPIE Conference on Multisensor, Multisource Information Fusion: Architectures, Algorithms, and Applications, Kissimmee, FL, 2006, Vol, 6242.
- [38] Anderson B D O, J B, Moore. Optimal Filtering. Englewood Cliffs, NJ: Prentice-Hall, 1979.
- [39] Chang K C, R K Saha, Y Bar-Shalom. On optimal track-to-track fusion. IEEE Transactions on Aerospace and Electronic Systems, 1997, 33: 1271–1276.

- [40] Liggins II, M E, C Y Chong, et al. Distributed fusion architectures and algorithms for target tracking. Proceedings of IEEE, 1997, 85: 95–107.
- [41] Chong C Y, S Mori, K C Chang, et al. Architectures and algorithms for track association and fusion. IEEE Aerospace and Electronic Systems Magazine, 2000, 15: 5–13.
- [42] Chong C Y, S Mori. Distributed fusion and communication management for target identification. In Proceedings of the 8th International Conference on Information Fusion, Philadelphia, PA, 2005.
- [43] 赵宗贵, 刁联旺. 信息融合工程实践——技术与方法. 北京: 国防工业出版社, 2015.

# 第 5 章 多传感器分布式目标检测

## 5.1 分布式检测问题描述

### 5.1.1 集中式与分布式检测

在很多实际场景中都面临判断问题。基于获得的观测信息进行判断，即从产生该观测的可能现象集合中进行判断选择，确定该现象的性质，以进一步确定应对该现象的行动方案。例如金融机构、石油勘探、医疗诊断、电子网络、天气预报、交通管制及军事指挥控制等领域，都建立了进行现象判断和行动选择的决策机构。在基于传感器的感知领域，传统方法是传感器将其原始观测信息传递给一个处理器，该处理器基于统计方法进行目标出现判断和检测，支持该类问题的理论基础就是统计学的一个分支——统计判定理论或假设检验理论<sup>[1]</sup>，在雷达和通信领域称为检测理论<sup>[2-5]</sup>。当多传感器观测一个现象时，为了进行判定，所有传感器的原始观测都要传递给一个中心处理器（称融合中心），在那里基于传统判定理论设计一个最优判定准则，以基于多传感器的原始观测产生最优判定结果。这种基于多传感器测量的集中式检测需要占用较大的通信带宽和能量消耗（无线传感网络中），并且中心处理器具有较重的计算负载，因此效率较低。

为克服集中式检测的弊端，人们提出分布式检测方法<sup>[2,6,7]</sup>，其中多个检测器（传感器）协同工作，以对两个或多个假设结论进行判定。在一个二元分布检测问题中，目的是确定一个关注的信号或目标出现或不存在；在一个多假设检验问题中则是基于特征对多个信号或目标进行归类<sup>[9-11]</sup>。

在图 5.1 所示的集中式检测结构中，融合中心对各传感器上报到观测空间的观测点  $\mathbf{Z}=(z_1, \dots, z_K)^T$  进行融合计算并按集中判定准则统计判定产生最优全局检测结果。在图 5.2 所示的分布式检测结构中，每个传感器基于自身的局部观测，也可参照前面传感器的检测结果，计算局部统计量并按设定的（通常采用相同的）局部判定准则产生局部检测结果  $u_k$  ( $k=1, \dots, K$ )。融合中心对传递到判定空间的局部判定向量  $\mathbf{u}=(u_1, \dots, u_K)^T$  进行融合（称为判定融合），按全局最优准则进行全局判定产生最优全局检测结果。由于各局部判定  $u_k$  仅由一维数据（0 或 1）构成，数据量大大低于局部原始观测向量  $\mathbf{Z}=(z_1, \dots, z_K)^T$ ，故分布式融合仅需较低的通信带宽，但是在局部判定向量中某些分量相容性较低或冲突时，融合中心采用的判定融合算法难度较大，并且由于各局部统计判定会损失一定原始观测信息，故分布式检测性能明显低于集中式检测。

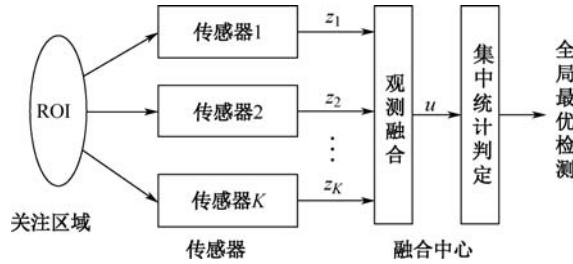


图 5.1 集中式检测结构

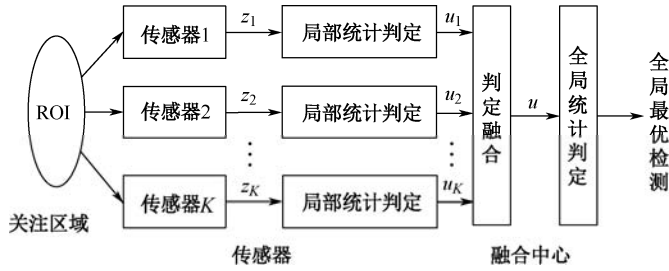


图 5.2 分布式检测结构

无论是集中式检测结构还是分布式检测结构，每个传感器的局部检测和融合中心的全局检测所采用的最优判定准则无非有两类，一类是贝叶斯准则，它可以使判定风险极小化；另一类是奈曼—皮尔逊（Neyman—Pearson, NP）准则，它是在固定的虚警率（该虚警率在满足需求的范围内）之下，使检测概率极大化。这两类判定准则的理论依据都是判定结论的后验概率达极大。我们在这里以二元（二值假设）确定性判定问题为例，描述分布式检测的原理和方法。令两假设为

$$H_0: \text{信号未出现} \quad (5.1)$$

$$H_1: \text{信号出现}$$

以  $z_k (1 \leq k \leq K)$  表示第  $k$  个传感器的原始观测：

$$z_k = \begin{cases} n_k & \text{在假设 } H_0 \text{ 下} \\ \theta + n_k & \text{在假设 } H_1 \text{ 下} \end{cases} \quad (5.2)$$

式中， $\theta$  表示刻画假设  $H_1$  特征的参数向量， $n_k$  为噪声向量。以  $u_k$  表示第  $k$  个传感器的判定结果：

$$u_k = \begin{cases} 1 & \text{若假设 } H_1 \text{ 真} \\ 0 & \text{若假设 } H_0 \text{ 真} \end{cases} \quad k = 1, \dots, K \quad (5.3)$$

### 5.1.2 分布式检测结构与模型<sup>[12,13]</sup>

分布式检测系统有两类结构：串行检测结构和并行检测结构，分别如图 5.3 和图 5.4 所示。在图 5.3 所示的串行检测结构中，每个传感器基于自身局部观测和前一传感器的检测结果，按一定检测准则产生其检测结果。该结构中  $u_K$  就是系统的最终检测结果，它是基于前  $K-1$  个传感器的累计判定信息和第  $K$  个传感器的测量  $z_K$  产生的。由于基于准则  $\gamma_K$  产生  $u_K$  时，丢弃了前面  $K-1$  个传感器的测量信息  $z_1, \dots, z_{K-1}$ ，而  $u_1, \dots, u_{K-1}$  按相应准则生成时也可能损失一定的观测信息，因此串行检测结构性能低于集中式检测。

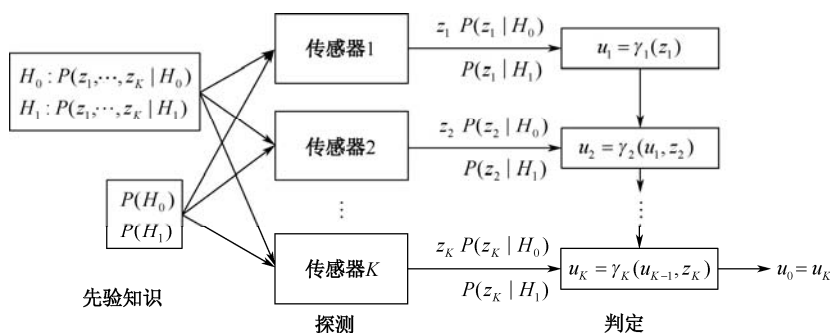


图 5.3 串行检测结构

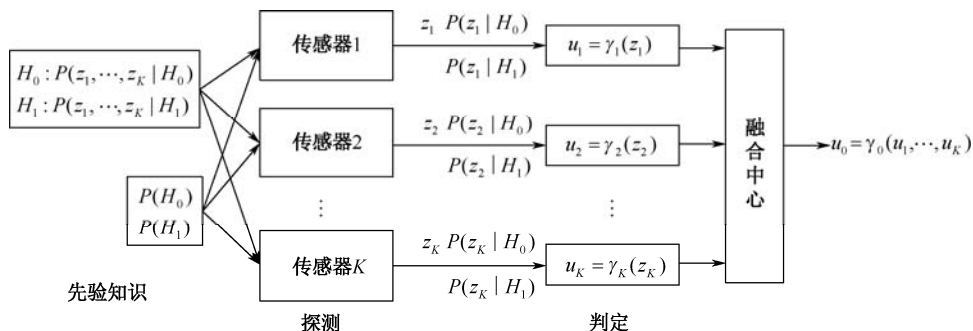


图 5.4 并行检测结构

在图 5.4 所示的并行检测结构中，每个传感器基于自身局部观测，按相应准则产生检测结果，该结构设置一个融合中心，该中心基于各传感器生成的局部检测向量  $\mathbf{u} = (u_1, \dots, u_K)$  按全局融合准则产生最终检测结果。并行检测结构中各传感器的局部检测可独立进行，也可按照融合中心的反馈协调优化。以  $P(H_0) = P_0$  和  $P(H_1) = P_1$  分别表示假设  $H_0$  和  $H_1$  的先验概率， $P_0(\theta)$ 、 $P_1(\theta)$  分别为相应的概率密度，这里  $\theta$  表示特征参数向量。于是， $P_F = P(u_0 = 1 | H_0)$  和  $P_M = P(u_0 = 0 | H_1)$  分别为全局融合判定的虚警概率（Probability of False）和漏警概率（Probability of Miss）。在分布式检测中，融合中心采取的理性判定准则应该是：在给定局部判定向量  $\mathbf{u}$  的情况下，判定接受条件概率大的假设，即

$$\begin{cases} P(H_1 | \mathbf{u}) \geq P(H_0 | \mathbf{u}) & \text{接受 } H_1 \\ P(H_1 | \mathbf{u}) < P(H_0 | \mathbf{u}) & \text{接受 } H_0 \end{cases} \quad (5.4)$$

该判定准则可改写为

$$\begin{cases} \frac{P(H_1 | \mathbf{u})}{P(H_0 | \mathbf{u})} \geq 1 & \text{接受 } H_1 \\ \frac{P(H_1 | \mathbf{u})}{P(H_0 | \mathbf{u})} < 1 & \text{接受 } H_0 \end{cases} \quad (5.5)$$

这就是极大后验（Maximum Posteriori）概率准则。

应用条件概率公式  $P(H_i | \mathbf{u}) = \frac{P(\mathbf{u} | H_i) P(H_i)}{P(\mathbf{u})}$  ( $i = 0, 1$ )，可以导出似然比判定准则：



$$\Lambda(\mathbf{u}) = \begin{cases} \frac{P(\mathbf{u}|H_1)}{P(\mathbf{u}|H_0)} > \frac{P(H_0)}{P(H_1)} = \lambda & \text{接受 } H_1 \\ \frac{P(\mathbf{u}|H_1)}{P(\mathbf{u}|H_0)} < \frac{P(H_0)}{P(H_1)} = \lambda & \text{接受 } H_0 \end{cases} \quad (5.6)$$

式中,  $\Lambda(\mathbf{u})$  为似然比, 式 (5.6) 又被称为似然比检验 (LRT)。不同的统计检验准则最终都能够表示为 LRT 形式, 只是式 (5.6) 右侧的门限  $\lambda$  的表达式有所不同。

本章重点描述如图 5.4 所示的二元分布式并行检测方法, 该方法在网络连接环境下已有广泛应用。分布式并行检测与串行不同, 它分为两个层次进行, 即双层检测模型。问题面对的是求取各传感器局部最优检测向量  $\mathbf{u} = (u_1, \dots, u_K)$  ( $u_k = \gamma_k(z_k)$ ,  $k = 1, \dots, K$ ) 和全局最优检测向量  $\mathbf{u}_0 = \gamma_0(\mathbf{u}) = \gamma_0(u_1, \dots, u_K)$ , 这实际上是确定最优检测准则 ( $\gamma_0, \gamma_1, \dots, \gamma_K$ ) 问题。下面分别介绍二元分布式检测的贝叶斯准则和 NP 准则。

本节最后需提及的是当前方兴未艾的无线传感器网络 (Wireless Sensor Networks, WSN) 对分布式检测的特定需求<sup>[8]</sup>。一个 WSN 由大量低成本和低功率传感器组成, 用于收集来自其部署域内的关注事件的观测。其中, 每个传感器从原始观测信息中提取关注信息, 并借助无线信道与其他传感器或融合中心节点通信。由于 WSN 在功率和带宽等资源能力上存在严格限制, 因此需要设计适宜的分布融合算法才能满足 WSN 资源约束。进一步说, 在无线信道上, 将传感器测量无误差地实时传输到融合中心节点, 需要较高的传输功率、带宽和有效的误差校验代码, 而这些可能超出传感器的有限功率和处理能力。因此, WSN 中的分布检测系统设计必须考虑信道衰减, 从原始测量信息中提取出满足融合检测需求的最小充分统计量并设计适宜的效费比信息共享算法, 尽量减少带宽占用<sup>[14-16]</sup>。WSN 部署的灵活性、机动性及健壮性使其在战场监视和环境监测领域获得广泛应用, 其中, WSN 面对目标 (信号) 发现的检测能力成为各种应用的关键。文献[20,21]概括了 WSN 中的分布式目标检测、估计和跟踪的研究成果。

## 5.2 基于 LRT 的分布式检测方法<sup>[18,19]</sup>

### 5.2.1 贝叶斯分布式检测

贝叶斯检测方法是在分布式并行检测中通过采用贝叶斯准则使基于后验概率的贝叶斯判定风险 (代价) 达极小实现的。

#### 1. 基于 LRT 的贝叶斯检测方法<sup>[22]</sup>

设输入融合中心的各传感器的判定向量是  $\mathbf{u} = (u_1, \dots, u_K)$ , 将融合中心的判定空间  $U$  进行分解,  $U = U_0 \cup U_1$ ,  $U_0 \cap U_1 = \emptyset$ ,  $U_i$  是对应于假设  $H_i$  成立的判定域, 即对任何落入  $U_i$  中的判定向量  $\mathbf{u}_0$ , 宣布  $H_i$  为真, 即  $u_0 = i$  ( $i = 0, 1$ )。

在二元假设检验问题中, 可能出现 4 种判定结果:

① 假设  $H_0$  为真时, 判定接受  $H_0$  ( $u_0 = 0$ );

- ② 假设  $H_1$  为真时, 判定接受  $H_1$  ( $u_0=1$ );
- ③ 假设  $H_0$  为真时, 判定接受  $H_1$  ( $u_0=1$ );
- ④ 假设  $H_1$  为真时, 判定接受  $H_0$  ( $u_0=0$ )。

其中前两者对应正确的选择, 后两者对应错误的选择, ③称为第一类风险, 即虚警, ④称为第二类风险, 即漏警。无论是正确的选择还是错误的选择都要付出代价, 而不同的选择会导致不同的后果。如在反导系统中, 漏警的风险代价最大, 而虚警则风险代价小一些。在一般的防空系统中, 漏警和虚警的风险代价的差别可能小于反导系统。定义  $C_{ij}$  为假设  $H_j$  为真时作出判决接受  $H_i$  的代价, 则基于概率判定的平均风险代价为

$$R = C_{00}P(u_0=0|H_0) + C_{10}P(u_0=1|H_0) + C_{01}P(u_0=0|H_1) + C_{11}P(u_0=1|H_1)$$

应用条件概率公式得

$$R = C_{00}P(u_0=0|H_0)P(H_0) + C_{10}P(u_0=1|H_0)P(H_0) + C_{01}P(u_0=0|H_1)P(H_1) + C_{11}P(u_0=1|H_1)P(H_1) \quad (5.7)$$

其中先验概率  $P(H_0)$  和  $P(H_1)$  视为已知。条件概率  $P(u_0=i|H_j)$   $i, j=0,1$  可视为  $H_j$  已知时, 判定向量  $\mathbf{u}$  落入  $U_i$  的概率, 故

$$P(\mathbf{u}=i|H_j) = \int_{U_i} p(\mathbf{u}|H_j) d\mathbf{u} \quad (5.8)$$

其中  $p(\mathbf{u}|H_j)$  是相应的条件概率密度。于是平均风险化为

$$R = C_{00}P(H_0) \int_{U_0} p(\mathbf{u}|H_0) d\mathbf{u} + C_{10}P(H_0) \int_{U_1} p(\mathbf{u}|H_0) d\mathbf{u} + C_{01}P(H_1) \int_{U_0} p(\mathbf{u}|H_1) d\mathbf{u} + C_{11}P(H_1) \int_{U_1} p(\mathbf{u}|H_1) d\mathbf{u} \quad (5.9)$$

由于  $U = U_1 \cup U_0$ , 故

$$\begin{aligned} \int_{U_1} p(\mathbf{u}|H_i) d\mathbf{u} &= \int_U p(\mathbf{u}|H_i) d\mathbf{u} - \int_{U_0} p(\mathbf{u}|H_i) d\mathbf{u} \\ &= 1 - \int_{U_0} p(\mathbf{u}|H_i) d\mathbf{u} \quad i=0,1 \end{aligned} \quad (5.10)$$

因此, 式 (5.9) 可化为

$$\begin{aligned} R &= C_{10}P(H_0) + C_{11}P(H_1) + \int_{U_0} p(H_1)[C_{01} - C_{11}]p(\mathbf{u}|H_1) d\mathbf{u} + \\ &\quad \int_{U_0} p(H_0)[C_{00} - C_{10}]p(\mathbf{u}|H_0) d\mathbf{u} \\ &= c_{10}P(H_0) + c_{11}P(H_1) + \int_{U_0} \{p(H_1)[c_{01} - c_{11}]p(\mathbf{u}|H_1) - p(H_0)[c_{10} - c_{00}]p(\mathbf{u}|H_0)\} d\mathbf{u} \end{aligned} \quad (5.11)$$

由于正确判断的风险代价通常小于错误判断的风险代价, 可以假设

$$C_{01} > C_{11}, \quad C_{10} > C_{00}$$

为使总代价即贝叶斯风险代价  $R$  达极小, 式 (5.11) 右端积分项应小于零, 即被积函数为正时, 变量  $\mathbf{u} \notin U_0$ ; 而被积函数为负时, 变量  $\mathbf{u} \in U_0$ 。于是得判决规则如下:

$$\begin{aligned} p(H_1)[C_{01} - C_{11}]p(\mathbf{u} | H_1) - p(H_0)[C_{10} - C_{00}]p(\mathbf{u} | H_0) &> 0 & \mathbf{u} \in U_1 \\ p(H_1)[C_{01} - C_{11}]p(\mathbf{u} | H_1) - p(H_0)[C_{10} - C_{00}]p(\mathbf{u} | H_0) &< 0 & \mathbf{u} \in U_0 \end{aligned}$$

可以得到似然比检验准则：

$$\Lambda(\mathbf{u}) = \begin{cases} \frac{P(\mathbf{u} | H_1)}{P(\mathbf{u} | H_0)} \geq \frac{P(H_0)(C_{10} - C_{00})}{P(H_1)(C_{01} - C_{11})} = \lambda & \text{接受 } H_1 \\ \frac{P(\mathbf{u} | H_1)}{P(\mathbf{u} | H_0)} < \frac{P(H_0)(C_{10} - C_{00})}{P(H_1)(C_{01} - C_{11})} = \lambda & \text{接受 } H_0 \end{cases} \quad (5.12)$$

易见，当  $C_{10} - C_{00} = C_{01} - C_{11}$  时，贝叶斯似然比检测准则（5.12）变为极大后验概率准则（5.6）。

## 2. 基于局部 LRT 检测的全局最优检测

在各传感器采用的检测准则  $\gamma_i (i=1, \dots, K)$  确定的情况下，各传感器基于自身观测  $z_i$  独立判定，产生各自的局部检测结果  $u_i$ ，此时输入融合中心的局部检测向量  $\mathbf{u} = (u_1, \dots, u_K)$  各分量相互独立，融合中心仅对各局部判决分量进行综合产生全局检测结果，并不反馈协调和改善各局部检测性能。

二值变量  $u_k$  的条件分布概率  $P(u_k | H_j) (k=1, 2, \dots, K; j=0, 1)$  如表 5.1 所示。

表 5.1 二值变量  $u_k$  的条件分布概率

$H_j \backslash u_k$	0	1
$H_0$	$1 - P_{f_k}$	$P_{f_k}$
$H_1$	$1 - P_{d_k}$	$P_{d_k}$

表 5.1 中：

$P_{f_k} = P(u_k = 1 | H_0)$  为传感器  $k$  的虚警概率；

$P_{d_k} = P(u_k = 1 | H_1)$  为传感器  $k$  检测出信号出现的概率；

$1 - P_{d_k} = P(u_k = 0 | H_1)$  为传感器  $k$  的漏检概率；

$1 - P_{f_k} = P(u_k = 0 | H_0)$  为传感器  $k$  检测出信号未出现的概率。

在全局检测判定空间  $U$  中，各传感器的局部检测结果  $u_k$ （二值变量）作为全局检测的输入，从表 5.1 不难看出，可以假设  $u_k$  的条件似然比为

$$\Lambda(u_k) = \frac{P(u_k | H_1)}{P(u_k | H_0)} = \begin{cases} (1 - P_{d_k}) / (1 - P_{f_k}) & u_k = 0 \\ P_{d_k} / P_{f_k} & u_k = 1 \end{cases} \quad k = 1, 2, \dots, K \quad (5.13)$$

这样一来，在各分量  $u_k$  相互独立的情况下，融合中心的全局似然比判决式（5.12）可以化为

$$\Lambda(\mathbf{u}) = \begin{cases} \frac{P(\mathbf{u} | H_1)}{P(\mathbf{u} | H_0)} = \prod_{k=1}^K \frac{P(u_k | H_1)}{P(u_k | H_0)} = \prod_{k \in S_1} \frac{P_{d_k}}{P_{f_k}} \prod_{k \in S_0} \frac{1 - P_{d_k}}{1 - P_{f_k}} \geq \lambda_0 & \text{接受 } H_1 \\ \frac{P(\mathbf{u} | H_1)}{P(\mathbf{u} | H_0)} = \prod_{k=1}^K \frac{P(u_k | H_1)}{P(u_k | H_0)} = \prod_{k \in S_1} \frac{P_{d_k}}{P_{f_k}} \prod_{k \in S_0} \frac{1 - P_{d_k}}{1 - P_{f_k}} < \lambda_0 & \text{接受 } H_0 \end{cases} \quad (5.14)$$

式中,  $s_1$  为  $u_k=1$  的下标集合,  $s_0$  为  $u_k=0$  的下标集合。(5.14) 式右端的门限值为

$$\lambda_0 = \frac{P(H_0)(C_{10} - C_{00})}{P(H_1)(C_{01} - C_{11})} \triangleq \frac{C_F}{C_D} \quad (5.15)$$

式(5.14)和式(5.15)就是基于各传感器局部判定结果  $u_k (k=1, \dots, K)$  并且各  $u_k$  相互独立情况下所导出的融合中心二元全局似然比判定公式。从中可以看出, 融合中心的似然比  $\Lambda(\mathbf{u})$  为各局部传感器似然比之积, 可以通过系统输入的各传感器判定结果  $\{u_k=0, 1\}_{k=1}^K$  及其似然比判定采用的虚警率和检测率  $\{P_{f_k}, P_{d_k}\}_{k=1}^K$  计算出来。融合中心似然比判定门限则由全局检测的两假设先验概率及容许的贝叶斯风险确定, 如式(5.15)所示。融合中心的虚警率和检测率分别为

$$P_F = \sum_{\Lambda(\mathbf{u}) > \lambda_0} P[\Lambda(\mathbf{u})|H_0], \quad P_D = \sum_{\Lambda(\mathbf{u}) > \lambda_0} P[\Lambda(\mathbf{u})|H_1] \quad (5.16)$$

其中  $P[\Lambda(\mathbf{u})|H_j]$  ( $j=0, 1$ ) 是  $H_j$  条件下, 似然比统计量  $\Lambda(\mathbf{u})$  的概率分布。由式(5.14)可知融合中心似然比是各传感器局部似然比之积, 即  $\Lambda(\mathbf{u}) = \prod_{k=1}^K \Lambda(u_k)$ , 并且各传感器相互独立, 于是可知  $\Lambda(\mathbf{u})$  的概率分布是各因子  $\Lambda(u_k)$  的联合分布:

$$P[\Lambda(\mathbf{u})|H_j] = P_1[\Lambda(u_1)|H_j] * P_2[\Lambda(u_2)|H_j] * \dots * P_K[\Lambda(u_K)|H_j] \quad (5.17)$$

这里每两个独立随机变量之积的联合概率分布为(见文献[85]中二随机变量之积的分布)

$$P(x_1, x_2) = P(x_1) * P(x_2) = \int P_1(x_1) P_2(x_2) \frac{dx_1}{|x_1|} = \int P_1(x_2) P_2(x_1) \frac{dx_2}{|x_2|}$$

式中,  $|x_i|$  为变量  $x_i$  的维数。

注意式(5.13), 可以得到各传感器似然比  $\Lambda(u_k)$  在其两个取值点上的条件概率分布与二值布尔函数  $u_k$  的概率分布相同, 于是得到:

$$\begin{aligned} P[\Lambda(u_k)|H_0] &= P(u_k=0|H_0) + P(u_k=1|H_0) \\ &= (1-P_{f_k})\delta[\Lambda(u_k) - \frac{1-P_{d_k}}{1-P_{f_k}}] + P_{f_k}\delta[\Lambda(u_k) - \frac{P_{d_k}}{P_{f_k}}] \\ P[\Lambda(u_k)|H_1] &= P(u_k=0|H_0) + P(u_k=1|H_1) \\ &= (1-P_{d_k})\delta[\Lambda(u_k) - \frac{1-P_{d_k}}{1-P_{f_k}}] + P_{d_k}\delta[\Lambda(u_k) - \frac{P_{d_k}}{P_{f_k}}] \end{aligned} \quad k=1, \dots, K \quad (5.18)$$

式中, 狄拉克函数  $\delta(x) = \begin{cases} 1 & x=0 \\ 0 & x \neq 0 \end{cases}$ 。

### 3. 基于 LRT 的局部最优检测

由式(5.7)和式(5.15)不难得出融合中心二元判定的贝叶斯风险为

$$\begin{aligned} R &= \sum_{i=0}^1 \sum_{j=0}^1 C_{ij} P(H_i) P(u_0=i|H_j) \\ &= C + C_F P(u_0=1|H_0) - C_D P(u_0=1|H_1) \end{aligned} \quad (5.19)$$

式中,  $u_0$  为融合中心全局判定结果,  $C_F = P_0(C_{01} - C_{00})$ ,  $C_D = (1 - P_0)(C_{01} - C_{11})$ ,  $C = C_{01}(1 - P_0) + C_{00}P_0$ ,  $P_0 = P(H_0)$ 。

令  $\mathbf{u} = [u_1, u_2, \dots, u_K]$ ,  $\mathbf{u}^k = [u_1, \dots, u_{k-1}, u_{k+1}, \dots, u_K]$ ,  $\mathbf{u}^{kj} = [u_1, \dots, u_{k-1}, j, u_{k+1}, \dots, u_K]$  ( $j = 0, 1$ )。

注意:

$$\begin{aligned} P(u_0 = 1 | H_j) &= \sum_{\mathbf{u}} P(u_0 = 1, \mathbf{u} | H_j) = \frac{1}{K-1} \sum_{\mathbf{u}^k} P(u_0 = 1, \mathbf{u}^k | H_j) \\ &= \frac{1}{K-1} \sum_{\mathbf{u}^k} P(u_0 = 1 | \mathbf{u}^k, H_j) P(\mathbf{u}^k | H_j) \\ &= \frac{1}{K-1} \sum_{\mathbf{u}^k} P(u_0 = 1 | \mathbf{u}^k) P(\mathbf{u}^k | H_j) \end{aligned} \quad (5.20)$$

于是贝叶斯风险为

$$\begin{aligned} R &= C + C_F P(u_0 = 1 | H_0) - C_D P(u_0 = 1 | H_1) \\ &= C + \frac{1}{K-1} \sum_{\mathbf{u}^k} [C_F P(u_0 = 1 | \mathbf{u}^k) P(\mathbf{u}^k | H_0) - C_D P(u_0 = 1 | \mathbf{u}^k) P(\mathbf{u}^k | H_1)] \\ &= C + \frac{1}{K-1} \sum_{\mathbf{u}^k} \left\{ \begin{aligned} &P(u_0 = 1 | \mathbf{u}^{k_1}) [C_F P(\mathbf{u}^{k_1} | H_0) - C_D P(\mathbf{u}^{k_1} | H_1)] + \\ &P(u_0 = 1 | \mathbf{u}^{k_0}) [C_F P(\mathbf{u}^{k_0} | H_0) - C_D P(\mathbf{u}^{k_0} | H_1)] \end{aligned} \right\} \\ &= C + \frac{1}{K-1} \sum_{\mathbf{u}^k} \left\{ \begin{aligned} &P(u_0 = 1 | \mathbf{u}^{k_1}) [C_F P(\mathbf{u}^{k_1} | H_0) - C_D P(\mathbf{u}^{k_1} | H_1)] + \\ &P(u_0 = 1 | \mathbf{u}^{k_0}) \{ C_F [P(\mathbf{u}^k | H_0) - P(\mathbf{u}^{k_1} | H_0)] - C_D [P(\mathbf{u}^k | H_1) - P(\mathbf{u}^{k_1} | H_1)] \} \end{aligned} \right\} \\ &= C + \frac{1}{K-1} \sum_{\mathbf{u}^k} P(u_0 = 1 | \mathbf{u}^{k_0}) [C_F P(\mathbf{u}^k | H_0) - C_D P(\mathbf{u}^k | H_1)] + \\ &\quad \frac{1}{K-1} \sum_{\mathbf{u}^k} [P(u_0 = 1 | \mathbf{u}^{k_1}) - P(u_0 = 1 | \mathbf{u}^{k_0})] [C_F P(\mathbf{u}^{k_1} | H_0) - C_D P(\mathbf{u}^{k_1} | H_1)] \\ &= C_k + \frac{1}{K-1} \sum_{\mathbf{u}^k} \{ A(\mathbf{u}^k) [C_F P(\mathbf{u}^{k_1} | H_0) - C_D P(\mathbf{u}^{k_1} | H_1)] \} \end{aligned} \quad (5.21)$$

式中,  $C_k = C + \frac{1}{K-1} P(u_0 = 1) | \mathbf{u}^{k_0} [C_F P(\mathbf{u}^k | H_0) - C_D P(\mathbf{u}^k | H_1)]$ ,  $A(\mathbf{u}^k) = P(u_0 = 1 | \mathbf{u}^{k_1}) - P(u_0 = 1 | \mathbf{u}^{k_0})$ 。

式 (5.21) 将融合中心的检测 ( $u_0 = 1$ ) 风险  $R$  与第  $k$  个传感器 ( $k = 1, \dots, K$ ) 的局部检测结果 ( $\mathbf{u}^{k_1}, \mathbf{u}^{k_0}$ ) 联系起来。为了基于全局检测优化局部传感器检测结果, 假设该系统由两级检测构成, 该两级检测系统的输入为  $K$  个传感器的测量样本  $Z = (z_1, z_2, \dots, z_K)$ 。仿  $\mathbf{u}^k$  的定义, 设:

$$Z^k = (z_1, \dots, z_{k-1}, z_{k+1}, \dots, z_K),$$

即  $Z^k$  中不包含  $Z$  中的第  $k$  个传感器测量样本,  $Z = \{Z^k, z_k\}$ 。

根据各传感器测量的独立性假设, 基于  $Z^k$  和  $Z$  的后验判决概率有如下关系:

$$P(\mathbf{u}^{k_1} | Z) = P(\mathbf{u}^k = i | z_k) P(\mathbf{u}^k | Z^k) \quad i = 0, 1$$

为了讨论各传感器的局部检测门限, 在各传感器测量和检测均独立的条件下, 将  $P(\mathbf{u}^{k_1} | H_j)$  在局部传感器测量样本集合上展开:

$$\begin{aligned}
P(\mathbf{u}^{k_i} | H_j) &= \int_Z P(\mathbf{u}^{k_i} | Z) f(Z | H_j) dZ \\
&= \int_Z P(u_k = i | z_k) P(\mathbf{u}^k | Z^k) f(Z | H_j) dZ \\
&= \int_{z_k} P(u_k = i | z_k) \left[ \int_{Z^k} P(\mathbf{u}^k | Z^k) f(z_k, Z^k | H_j) dZ^k \right] dz_k \\
&= \int_{z_k} P(u_k = i | z_k) \left[ \int_{Z^k} P(\mathbf{u}^k | Z^k) f(Z^k | H_j) dZ^k \right] f(z_k | H_j) dz_k
\end{aligned} \tag{5.22}$$

式中,  $f(Z | H_j)$  为假设  $H_j$  的情况下, 样本  $Z = \{Z^k, z_k\}$  的概率密度 (似然函数)。

将式 (5.22) 所示的  $P(\mathbf{u}^{k_i} | H_j)$  代入式 (5.21), 得到贝叶斯风险为

$$R = C_k + \frac{1}{K-1} \int_{z_k} P(u_k = 1 | z_k) \left\{ \sum_{\mathbf{u}^k} \left[ A(\mathbf{u}^k) \int_{Z^k} P(\mathbf{u}^k | Z^k) [C_F f(Z^k | H_0) f(z_k | H_0) - C_D f(Z^k | H_1) f(z_k | H_1)] dZ^k \right] \right\} dz_k$$

再注意

$$\int_{Z^k} P(\mathbf{u}^k | Z^k) f(Z^k | H_j) dZ^k = P(\mathbf{u}^k | H_j) = \prod_{\substack{m=1 \\ m \neq k}}^K P(u_m | H_j)$$

于是

$$R = C_k + \frac{1}{K-1} \int_{z_k} P(\mathbf{u}^k = 1 | z_k) \left\{ \sum_{\mathbf{u}^k} \left[ A(\mathbf{u}^k) \prod_{\substack{m=1 \\ m \neq k}}^K [C_F P(u_m | H_0) f(z_k | H_0) - C_D P(u_m | H_1) f(z_k | H_1)] \right] \right\} dz_k \tag{5.23}$$

为了使贝叶斯风险达极小, 式 (5.23) 中积分项必须小于零, 于是下式必然成立

$$\begin{cases} \sum_{\mathbf{u}^k} A(\mathbf{u}^k) \left\{ \prod_{\substack{m=1 \\ m \neq k}}^K [C_F P(u_m | H_0) f(z_k | H_0) - C_D P(u_m | H_1) f(z_k | H_1)] \right\} < 0 & P(u_k = 1 | z_k) = 1 \\ \sum_{\mathbf{u}^k} A(\mathbf{u}^k) \left\{ \prod_{\substack{m=1 \\ m \neq k}}^K [C_F P(u_m | H_0) f(z_k | H_0) - C_D P(u_m | H_1) f(z_k | H_1)] \right\} > 0 & P(u_k = 1 | z_k) = 0 \end{cases}$$

整理成传感器  $k$  的二元似然比判定形式, 得

$$\begin{cases} \frac{f(z_k | H_1)}{f(z_k | H_0)} \geq \frac{\sum_{\mathbf{u}^k} C_F A(\mathbf{u}^k) \prod_{\substack{m=1 \\ m \neq k}}^K P(u_m | H_0)}{\sum_{\mathbf{u}^k} C_D A(\mathbf{u}^k) \prod_{\substack{m=1 \\ m \neq k}}^K P(u_m | H_1)} = \lambda_k(u_0, \mathbf{u}^k) & u_k = 1 \\ \frac{f(z_k | H_1)}{f(z_k | H_0)} < \frac{\sum_{\mathbf{u}^k} C_F A(\mathbf{u}^k) \prod_{\substack{m=1 \\ m \neq k}}^K P(u_m | H_0)}{\sum_{\mathbf{u}^k} C_D A(\mathbf{u}^k) \prod_{\substack{m=1 \\ m \neq k}}^K P(u_m | H_1)} = \lambda_k(u_0, \mathbf{u}^k) & u_k = 0 \end{cases} \tag{5.24}$$

式 (5.24) 就是各传感器探测和判断皆独立假设下, 并且各传感器和融合中心皆采用 LRT 准则时, 传感器  $k$  的似然比判定  $u_k$  与其他传感器判定向量  $\mathbf{u}^k$  及融合中心判定结论  $u_0$  之间的

依赖关系。

然而，在给出二元假设先验概率与判定风险( $C_F, C_D$ )的情况下，式(5.24)右端所示的其他各传感器 LRT 门限是相互耦合的，因此他们以相互依赖的方式影响着系统性能。从图 5.4 描述的分布式并行检测结构可以看出，我们面对的问题是基于  $K$  个传感器测量  $z_1, \dots, z_K$  的二级检测问题，既要确定各传感器级的局部检测准则  $\{u_k = \gamma_k(z_1, \dots, z_K)\}_{k=1}^K$ ，又要确定融合中心的全局检测准则  $u_0 = r_0(u_1, \dots, u_K)$ ，也就是说要达到局部和全局检测结果的综合优化<sup>[16]</sup>。在各局部传感器测量独立和采用 LRT 准则进行检测判定的假设下，并不能完全解决这一问题。通常，人们从式(5.24)出发求取局部传感器检测门限  $\lambda_k$  几乎总是采用逐个优化(Person By Person Optimization, PBPO)方法，其中每个传感器的检测门限  $\lambda_k$  是在假设其他传感器和融合中心采用固定判定准则的情况下独自进行自身 LRT 优化<sup>[21]</sup>。PBPO 算法显然无法获得全局最优解，即便局部最优也是有条件的。为了获得全局最优，各传感器要进行多种初始化，即不断调整二元假设的先验概率和二元假设下的测量概率密度函数。

### 5.2.2 基于 LRT 的奈曼—皮尔逊检测方法

分布式检测问题的奈曼—皮尔逊(Neyman—Pearson, NP)公式的表述是：令  $\alpha$  是整个虚警概率的一个规定的边界，使  $P_F = P(u_0 = 1 | H_0) \leq \alpha$ 。于是，问题归结为寻求最优的各局部和全局判定规则，在  $P_F \leq \alpha$  约束下使全局检测概率  $P_D = P(u_0 = 1 | H_1)$  达极大，或使全局漏检概率  $P_M = 1 - P_D = P(u_0 = 0 | H_1)$  达极小。从文献[22]知，此时可将该约束极值问题化为无约束极值问题，其指标函数为

$$J = P_M + \lambda(P_F - \alpha) \quad (5.25)$$

式中， $\lambda$  为拉格朗日乘子， $\lambda \geq 0$ ，虚检和漏检概率分别为

$$P_F = \int_{U_1} P(\mathbf{u} | H_0) d\mathbf{u}$$

$$P_M = \int_{U_0} P(\mathbf{u} | H_1) d\mathbf{u}$$

在融合中心，输入是多传感器判定向量  $\mathbf{u} = (u_1, \dots, u_K)$ ，应用上述  $P_F$ 、 $P_M$  表达式，指标函数变为

$$\begin{aligned} J &= \int_{U_0} P(\mathbf{u} | H_1) d\mathbf{u} + \lambda \left( \int_{U_1} P(\mathbf{u} | H_0) d\mathbf{u} - \alpha \right) \\ &= \int_{U_0} P(\mathbf{u} | H_1) d\mathbf{u} + \lambda \left( 1 - \int_{U_0} P(\mathbf{u} | H_0) d\mathbf{u} - \alpha \right) \\ &= \lambda(1 - \alpha) + \int_{U_0} [P(\mathbf{u} | H_1) - \lambda P(\mathbf{u} | H_0)] d\mathbf{u} \end{aligned}$$

为使指标函数达极小，该式右端积分项应小于零，从而导致融合中心的全局似然比检验(LRT)如下<sup>[23,24]</sup>：

$$\begin{cases} \Lambda(\mathbf{u}) = \frac{P(\mathbf{u}|H_1)}{P(\mathbf{u}|H_0)} = \prod_{k=1}^K \Lambda(u_k) = \prod_{k=1}^K \frac{P(u_k|H_1)}{P(u_k|H_0)} \geq \lambda_0 & u_0 = 1 \\ \Lambda(\mathbf{u}) = \frac{P(\mathbf{u}|H_1)}{P(\mathbf{u}|H_0)} = \prod_{k=1}^K \Lambda(u_k) = \prod_{k=1}^K \frac{P(u_k|H_1)}{P(u_k|H_0)} < \lambda_0 & u_0 = 0 \end{cases} \quad (5.26)$$

式中,  $\lambda_0$  是融合中心 NP 检测指标式 (5.25) 中的拉格朗日乘子。在各传感器处, 基于 LRT 的局部似然比检验为

$$\begin{cases} \Lambda(z_k) = \frac{P(z_k|H_1)}{P(z_k|H_0)} \geq \lambda_k \\ \Lambda(z_k) = \frac{P(z_k|H_1)}{P(z_k|H_0)} < \lambda_k \end{cases} \quad k=1, 2, \dots, K \quad (5.27)$$

式中,  $\lambda_k$  是传感器  $k$  的 NP 检测指标中的拉格朗日乘子。式 (5.26) 和式 (5.27) 中与判别区域  $(U_1, U_0)$  和  $(Z_{0k}, Z_{1k})$  ( $k=1, 2, \dots, K$ ) 对应的似然比门限  $\lambda_0$  和  $\lambda_k$  可以通过给定虚警概率  $P_f(P_f) = \alpha$  使检测概率达极大或漏检概率达极小来确定。在实际应用中, 通常利用大量恒虚警采样检测统计获得。我们注意到判定门限  $\lambda_k$  ( $k=1, 2, \dots, K$ ) 和  $\lambda_0$  与采用的似然比融合逻辑有关, 将式 (5.26) 记为

$$u_0(\lambda_0, u_1, \dots, u_K) = \begin{cases} 1 & \Lambda(\mathbf{u}) > \lambda_0 \\ 0 & \Lambda(\mathbf{u}) < \lambda_0 \end{cases}$$

则在给定 LRT 统计门限  $\lambda_0$  下,  $u_0$  是  $u_k$  ( $k=1, \dots, K$ ) 的单调增布尔函数, 即

- ① 若  $u_k=0$ , 则  $u_0(\lambda, u_1, \dots, u_{k-1}, 0, u_{k+1}, \dots, u_K) = \begin{cases} 1 & \text{严格单调} \\ 0 & \text{非严格单调} \end{cases}$ ;
- ② 若  $u_k=1$ , 则  $u_0(\lambda, u_1, \dots, u_{k-1}, 1, u_{k+1}, \dots, u_K) = 1$  非严格单调。

我们知道, 对于  $K$  个二元输入和一个二元输出的二级确定性判定来说, 通常存在  $2^{2^K}$  个单调增融合逻辑。对于每个单调融合逻辑, 通过不同的大量恒虚警采样统计获得的检测门限可能是不同的, 因此只能在不同的单调融合逻辑下, 逐一求取诸门限  $\lambda_k$ , 通过比较确定局部最优门限。可想而知, 寻求所有融合逻辑的全局最优门限存在巨大工作量。此外, 由于各传感器判定门限相互耦合, 它们的相互依赖影响系统性能, 文献[21]提出的逐一优化的方法仅能获得一个局部最小。为获得全局最优, 需要枚举所有初始状态, 而这仅对较小的  $N$  值 (指输入和输出判定结果的应有组合数量) 有可能找到最优解, 因为单调融合逻辑数随  $N$  呈指数增长, 并且找到最优判定门限  $\lambda_k$  ( $k=0, 1, \dots, K$ ) 需要进行  $N-1$  维搜索。

为了实现融合中心的 NP 检验, 在统计获得似然判定门限  $\lambda_0$  之后, 还必须获得融合中心 LRT 统计量  $\Lambda(\mathbf{u})$  的条件概率分布  $P(\Lambda(\mathbf{u})|H_j)$   $j=0, 1$ 。因为各传感器似然比之间的独立性, 可采用上式 (5.13) 给出的各传感器 LRT 的统计量  $\Lambda(u_k)$   $k=1, \dots, K$  的联合概率分布获得, 也可将融合中心对数似然比  $\ln \Lambda(\mathbf{u})$  的条件概率分布表示为各传感器局部对数似然比的条件概率的卷积 (见文献[85]中随机变量之和的分布)。

$$P(\ln \Lambda(\mathbf{u}) / H_j) = P(\ln \Lambda(u_1) / H_j) * \dots * P(\ln \Lambda(u_K) / H_j) \quad j=0, 1 \quad (5.28)$$

式中, 两个概率分布的卷积为



$$f(t_1) * g(t_2) = \int_{-\infty}^{\infty} f(t_1)g(t_2)dt_2 = \int_{-\infty}^{\infty} f(t_2)g(t_1)dt_1$$

由式 (5.13) 可得:

$$\ln \Lambda(u_k) = \begin{cases} \ln\left(\frac{1-p_{d_k}}{1-p_{f_k}}\right) & u_k = 0 \\ \ln\left(\frac{p_{d_k}}{p_{f_k}}\right) & u_k = 1 \end{cases} \quad k=1, \dots, K \quad (5.29)$$

类似于式 (5.18) 的推导, 可导出式 (5.28) 中各局部对数似然比因子为

$$P(\ln \Lambda(u_k) | H_0) = (1-p_{f_k})\delta\left[\ln \Lambda(u_k) - \ln \frac{1-p_{d_k}}{1-p_{f_k}}\right] + p_{f_k}\delta\left[\ln \Lambda(u_k) - \ln \frac{p_{d_k}}{p_{f_k}}\right] \quad (5.30)$$

$$P(\ln \Lambda(u_k) | H_1) = (1-p_{d_k})\delta\left[\ln \Lambda(u_k) - \ln \frac{1-p_{d_k}}{1-p_{f_k}}\right] + p_{d_k}\delta\left[\ln \Lambda(u_k) - \ln \frac{p_{d_k}}{p_{f_k}}\right] \quad (5.31)$$

由于对数函数的严格单调性, LRT 等价于如下对数似然比检验 (LLRT), 于是式 (5.26) 等价于:

$$\ln \Lambda(\mathbf{u}) = \begin{cases} \sum_{k=1}^K \ln \Lambda(u_k) \geq \ln \lambda_0 & u_0 = 1 \\ \sum_{k=1}^K \ln \Lambda(u_k) < \ln \lambda_0 & u_0 = 0 \end{cases} \quad (5.32)$$

这样融合中心的虚警概率和检测概率分别为

$$P_F = \sum_{\Lambda(\mathbf{u}) > \lambda_0} P[\Lambda(\mathbf{u}) | H_0] = \sum_{\ln \Lambda(\mathbf{u}) > \ln \lambda_0} P[\ln \Lambda(\mathbf{u}) | H_0] \quad (5.33)$$

$$P_D = \sum_{\Lambda(\mathbf{u}) > \lambda_0} P[\Lambda(\mathbf{u}) | H_1] = \sum_{\ln \Lambda(\mathbf{u}) > \ln \lambda_0} P[\ln \Lambda(\mathbf{u}) | H_1] \quad (5.34)$$

## 5.2.3 基于 LRT 的融合检测逻辑设计

### 1. 二元简单假设融合逻辑

$K$  个传感器各自基于 LRT 准则的两假设局部检测产生判定结论  $u_k=0,1$  ( $k=1, \dots, K$ ), 融合中心采用每个传感器的二值判定输入, 基于 LRT 准则融合判定产生全局检测  $u_0=0,1$ , 其确定性二元检测逻辑判定式 (5.35) 可由式 (5.14) 给出。

$$\Lambda(\mathbf{u}) = \begin{cases} \prod_{k=1}^K \frac{P(u_k | H_1)}{P(u_k | H_0)} \geq \lambda_0 & u_0 = 1 \\ \prod_{k=1}^K \frac{P(u_k | H_1)}{P(u_k | H_0)} < \lambda_0 & u_0 = 0 \end{cases} \quad (5.35)$$

式中, 检测门限  $\lambda_0$  是采用最优准则确定的 (如基于 LRT 的贝叶斯准则获得的式 (5.15) 表示的门限, 而 5.2.2 节基于 NP 准则的融合中心全局 LRT 门限是通过式 (5.26) 的分析确

定的)。判定式 (5.35) 左端可以写为

$$\begin{aligned} \prod_{k=1}^K \frac{P(u_k | H_1)}{P(u_k | H_0)} &= \prod_{k=1}^K \left[ \frac{P(u_k = 1 | H_1)}{P(u_k = 1 | H_0)} \right]^{u_k} \left[ \frac{P(u_k = 0 | H_1)}{P(u_k = 0 | H_0)} \right]^{1-u_k} \\ &= \prod_{k=1}^K \left[ \frac{p_{d_k}}{p_{f_k}} \right]^{u_k} \left[ \frac{1-p_{d_k}}{1-p_{f_k}} \right]^{1-u_k} \end{aligned} \quad (5.36)$$

将式 (5.36) 代入式 (5.35), 然后两端取对数, 得到 Chair—Varshney 融合规则<sup>[25]</sup>

$$\begin{cases} \sum_{k=1}^K \left[ u_k \ln \frac{p_{d_k}}{p_{f_k}} + (1-u_k) \ln \frac{1-p_{d_k}}{1-p_{f_k}} \right] \geq \ln \lambda_0 & u_0 = 1 \\ \sum_{k=1}^K \left[ u_k \ln \frac{p_{d_k}}{p_{f_k}} + (1-u_k) \ln \frac{1-p_{d_k}}{1-p_{f_k}} \right] < \ln \lambda_0 & u_0 = 0 \end{cases} \quad (5.37)$$

整理得

$$\begin{cases} \sum_{k=1}^K a_k u_k \geq \eta & u_0 = 1 \\ \sum_{k=1}^K a_k u_k > \eta & u_0 = 0 \end{cases} \quad (5.38)$$

式中,

$$a_k = \ln \frac{p_{d_k}(1-p_{f_k})}{p_{f_k}(1-p_{d_k})}, \quad \eta = \ln \lambda_0 + \sum_{k=1}^K \ln \frac{1-p_{f_k}}{1-p_{d_k}} \quad (5.39)$$

由此可以看出, 在融合中心基于 LRT 的最优两假设确定性判定逻辑可以通过各输入的局部判定的一个加权和与一个门限进行比较来实现, 而各权值和门限值则依赖于各传感器局部检测概率和虚警概率以及全局检测门限。

值得指出的是, 当各局部判定具有相同的统计特性, 而采用相同的虚警率  $p_f$  和检测率  $p_d$  时, 式 (5.38) 和式 (5.39) 所示的 Chair—Varshney 融合规则简化为一个  $K$  入  $T$  出规则 ( $T \leq K$ ) 或一个计数规则, 即若有  $T$  个或更多局部判定为 1, 则全局判定  $u_0 = 1$ 。这个计数判定规则大大减少了计算复杂性和传输带宽。

## 2. 二元复合假设融合逻辑

上面给出的二元简单假设融合逻辑中基于每个假设的参数  $\theta$  是确定性情况下考虑各局部判定相互独立导出的, 例如引入两假设先验概率  $P_j = P(H_j)$  和条件似然函数  $P(u | H_j)$  ( $j = 0, 1$ ) 以及每个传感器基于自身观测的局部判定风险参数  $p_{d_k}$  和  $p_{f_k}$  都是确定性的。如果这些参数在一个范围内取值是未知的, 则会出现复合假设的情况, 即两假设中每一个都可能是复合假设, 相应的检测问题就呈现为二元复合假设检验形式, 在离散情况表现为多假设检验。如果  $\theta$  是两假设下具有已知概率密度的随机向量, 该 LRT 就能够扩展为一个复合检验:

$$\Lambda(\mathbf{u}) = \begin{cases} \frac{\int_{\theta_1} P(\mathbf{u} | q, H_1) P(q | H_1) dq}{\int_{\theta_0} P(\mathbf{u} | q, H_0) P(q | H_0) dq} \geq \eta & u_0 = 1 \\ \frac{\int_{\theta_1} P(\mathbf{u} | q, H_1) P(q | H_1) dq}{\int_{\theta_0} P(\mathbf{u} | q, H_0) P(q | H_0) dq} < \eta & u_0 = 0 \end{cases} \quad (5.40)$$

若  $\theta$  是随机的静态常数，我们可以使用两假设下该值的极大似然估计作为 LRT 中的真实值，从而进行通用似然比检验（General Likelihood Ratio Test, GLRT）：

$$\Lambda(\mathbf{u}) = \begin{cases} \frac{\max_{q \in \theta_1} P(\mathbf{u} | q, H_1)}{\max_{q \in \theta_0} P(\mathbf{u} | q, H_0)} \geq \eta & u_0 = 1 \\ \frac{\max_{q \in \theta_1} P(\mathbf{u} | q, H_1)}{\max_{q \in \theta_0} P(\mathbf{u} | q, H_0)} < \eta & u_0 = 0 \end{cases} \quad (5.41)$$

显然，式（5.41）包含了式（5.35）所示的 LRT，其在 NP 准则（固定  $P_F$  使  $P_D$  达极大）和贝叶斯准则（贝叶斯风险达极小）下是最优的，但需要知道  $P(\mathbf{u} | q, H_1)$  和  $P(\mathbf{u} | q, H_0)$  的完全知识，并且其基于局部  $\Lambda(\mathbf{u}_k) (k=1, \dots, K)$  的融合形式以及判定门限的求取太复杂，因此在实际应用中并不始终可用。在许多应用中，经常采用简单、健壮的次优检测方法<sup>[26]</sup>。例如在确定条件下，通过在观测上附加一个已知的随机共振（Stochastic Resonance, SR）噪声来改善检测性能<sup>[27]</sup>。文献[28]首次讨论了通过附加的 SR 噪声产生一个次优固定检测形式来改善检测结果的可能性，如果可能，就可以确定最佳的噪声类型，以在  $P_F$  不增加时使  $P_D$  达到极大。文献[29]讨论了“变量检测器”的概念和方法，其中将附加噪声作为待求变量。

我们在本章中重点关注多传感器并行局部检测结构，并且传感器数量或样本数量相对固定。此外，还存在串行和树状局部检测结构<sup>[30-33]</sup>，文献[34-36]讨论了任意分布检测拓扑结构的求解问题。在固定样本数量的检测中，融合中心在接收到传感器观测或局部判定的集合后，才能进行全局判定。在传感器数量或测量样本随时间递增的检测系统中，可采用序贯检测方法，即融合中心随传感器测量或局部判定结果的序贯到来，依次进行全局融合和判定<sup>[14]</sup>。序贯检测可选择在任一时间终止，产生最后检测结果，或者由于判定结果不理想而继续获取观测<sup>[37-41]</sup>，直到获得满意的全局检测结果为止。

### 3. 二元假设融合逻辑随传感器增加的渐近分析

在实际应用中，可能在某海域撒播或施放水声传感器建立无线传感器组网（Wireless Sensor Network, WSN）水下和水面探测系统，或者在某地域（靠近对方活动区域）分散配置振动传感器建立 WSN 地面和低空目标探测系统。在这两种场景下都可能出现传感器基于需求而不断增加的情况。二元假设检验面对这种传感器渐近增加情况产生的结果是，各传感器采用相同的判定规则是最优的<sup>[17,42]</sup>。也就是说，各传感器采用相同的判定规则能够使融合中心的融合和判定达到最优，而只产生很小的甚至没有什么损失。

对于任一合理的判定规则集  $\Gamma$ ，融合中心的判定误差概率随传感器数量  $K$  无限增加，按指数趋向于零。因此，比较融合中心采用的判定规则的优劣，可以采用下述判定误差率

$P_E(\Gamma)$  收敛到零的指数率来衡量:

$$\lim_{K \rightarrow \infty} \frac{\ln P_E(\Gamma)}{K} = \lim_{\varepsilon \rightarrow 0} \ln P_E(\Gamma)^\varepsilon \quad (5.42)$$

这表明,对于二元假设检验,所有传感器节点采用相同的局部判定规则能达到按判定误差指数渐近最优的效果<sup>[42]</sup>。文献[43]考察了由最优并行融合网络所获得的极小融合判定误差概率的精确渐近线和采用相同判定规则约束的系统,分析表明相同判定规则的约束对全局融合性能产生很小的甚至没有损失,它抓住了大系统的控制行为,适合应用到随传感器增加的渐近分布检测中,这将使问题结构简化并对其最优解能够有效理解。

需要再次指出的是,在各传感器采用相同的局部判定规则的情况下,如上文所指出的,会将融合中心的判定规则简化为一个计数判定规则,即  $K$  入  $T$  出 ( $T \leq K$ ) 规则。此时,在某个二元规则  $\gamma$  下,若 Chernoff 信息(即各传感器判定  $u_k=1$  的数量)超过原始观测信息(即所有  $u_k=1$  和  $u_k=0$  的数量之和  $K$ )的一半,则融合中心的全局二元判定  $u_0=1$  就是最优的<sup>[44]</sup>。许多实际应用<sup>[45]</sup>都达到了该要求,如检测高斯噪声中的确定性信号和使用最小平方法则检测器检测高斯噪声中的起伏信号等问题就是如此。在这些案例中,多传感器融合节点提供的增益超过了从每个传感器精确信息获得的裨益,即达到了整体大于部分之和的效果。

## 5.3 基于计数表决规则的 WSN 检测方法

### 5.3.1 计数表决检测方法

到目前为止,大多数分布检测的研究和应用成果是基于这样的假设:局部传感器的性能,即其信噪比(SNR)及检测概率和虚警概率对融合中心来说是已知的。5.2节给出的基于LRT的检测的各种技术和方法都是如此。但是对于由撒播或施放于某一空间范围中的无线传感器构成的传感器网络(WSN)来说,融合中心获取或估计各无线传感器性能可能很困难,因为所关注的目标信号对各局部传感器和融合中心的相对位置是未知的。甚至各局部传感器相对融合中心的位置也是未知的,并且将其检测信号传输给融合中心会产生很大带宽和功率耗费,对有限系统资源的一个WSN来说更是如此。在这种情况下融合中心采用视各局部传感器性能和检测规则及传感器和目标信号位置均未知的融合逻辑与判定规则会更好。也就是要同等对待每个传感器的检测结果,一个直观的求解方法是下述  $T/K$  计数表决判定规则:

$$\Lambda(\mathbf{u} / H_1) = \begin{cases} \sum_{k=1}^K u_k > T & u_0 = 1 \\ \sum_{k=1}^K u_k < T & u_0 = 0 \end{cases} \quad (5.43)$$

式中,  $T$  ( $T \leq K$ ) 是融合中心计数判定门限,由预先规定的虚警概率  $P_f$  确定。该规则又简称为计数规则,它是一个很有吸引力的判定方法,其实现简单,并且在一个带有随机、密集配置的低代价传感器节点的 WSN 中仅占用最少的通信带宽(仅传输“1”或“0”)就能获得很好的、满足需求的检测性能。在 5.2.3 节中,式(5.37)~式(5.39)给出的 Chair—Varshney 融合判定规则在各传感器检测具有相同的统计特性时,就呈现为一个  $T/K$  计数判定规则。

对于式 (5.2) 描述的传感器观测模型, 若假设各传感器独立观测且观测性能相同 (这里表现为各传感器具有相同的虚警概率  $P_f$  和检测概率  $P_d$ ), 此时, 在假设  $H_0$  的情况下, 检测总数  $\Lambda(\mathbf{u}) = \sum_{k=1}^K u_k$  服从二项分布, 对给出的门限  $T$ , 融合中心的虚警概率和检测概率如下:

$$P_F = \sum_{k=T}^K \binom{K}{k} p_f^k (1-p_f)^{K-k} \quad (5.44)$$

$$P_D = \sum_{k=T}^K \binom{K}{k} p_d^k (1-p_d)^{K-k} \quad (5.45)$$

其中,  $\binom{K}{k} = \frac{K!}{k!(K-k)!}$  为从  $K$  中取  $k$  的组合数。

在许多实际场景中, 由于在假设  $H_1$  的情况下, 各传感器判定并不独立, 如前所述, 传感器判定依赖于目标和每个传感器的相对位置 (很可能是动态配置或不断运动的随机变量)。此时融合中心的虚警概率和检测概率应按下述公式计算:

$$P_F = P(u_0 = 1 / H_0) = P(\Lambda(\mathbf{u}) > \eta / H_0) \quad (5.46)$$

$$P_D = P(u_0 = 1 / H_1) = P(\Lambda(\mathbf{u}) > \eta / H_1) \quad (5.47)$$

这里需要检验统计量  $\Lambda(\mathbf{u})$  的概率密度函数, 以确定全局检测门限  $\eta$  与检测风险之间的关系。在 5.2 节中, 式 (5.18) 给出了各传感器独立进行 LRT 判定之下, 融合中心条件似然比的概率密度  $P(\Lambda(\mathbf{u}) / H_j) (j=0,1)$  的计算公式, 而将式 (5.30) 和式 (5.31) 给出的各局部对数似然比条件概率  $P(\ln \Lambda(\mathbf{u}_k) / H_i) (i=0,1)$  代入式 (5.28), 容易得到融合中心对数似然比  $\ln \Lambda(\mathbf{u})$  的条件概率分布密度  $P(\ln \Lambda(\mathbf{u}) / H_j) (j=0,1)$  的计算公式。这里的计数统计量  $\Lambda(\mathbf{u}) = \sum_{k=1}^K u_k$  的分布密度计算公式可在文献[46-48]中找到。鉴于计算检验统计量  $\Lambda(\mathbf{u})$  的概率密度函数存在较大的难度, 人们度量融合中心的检测性能可以不采用虚警概率和检测概率, 而采用下述偏差系数来确定检测门限与容许风险偏差之间的关系。

$$D[\Lambda(\mathbf{u})] = \frac{[E(\Lambda / H_1) - E(\Lambda / H_0)]^2}{\text{Var}(\Lambda / H_0)} \quad (5.48)$$

其中仅需要计算全局判定统计量  $\Lambda(\mathbf{u})$  的头两阶矩, 这比求取  $\Lambda(\mathbf{u})$  的概率密度函数要容易得多。

### 5.3.2 多传感器全局表决检测准则

式 (5.43) 给出的融合中心检测的  $T/K$  表决准则可以表示为

$$u_0(\mathbf{u}) = \begin{cases} 1 & \sum_{k=1}^K u_k \geq T \\ 0 & \sum_{k=1}^K u_k < T \end{cases} \quad (5.49)$$

式中,  $(u_1, u_2, \dots, u_K)$  是  $K$  个传感器局部检测集合, 是融合中心的输入量,  $u_0$  是融合中心的全局判定结果。

若  $p_{d_k}$  和  $p_{f_k}$  分别表示第  $k$  个传感器的检测概率和虚警概率, 则融合中心的全局检测概率

和虚警概率分别为

$$P_D = \sum_{\mathbf{u}} u_0(\mathbf{u}) \prod_{s_0} (1 - p_{d_k}) \prod_{s_1} p_{d_k} \quad (5.50)$$

$$P_F = \sum_{\mathbf{u}} u_0(\mathbf{u}) \prod_{s_0} (1 - p_{f_k}) \prod_{s_1} p_{f_k} \quad (5.51)$$

式中,

$$s_0 = \{k | u_k = 0\}, s_1 = \{k | u_k = 1\} \quad (5.52)$$

$u_0(\mathbf{u}) = u_0(u_1, \dots, u_K)$  表示  $K$  个局部检测的各种可能组合状态, 用来确定  $s_0$  和  $s_1$  中所含有的局部检测元素。  $\sum_{\mathbf{u}}$  是对相应各种组合状态的局部检测概率和虚警概率求和。

具体案例: 当  $K=3$  时, 式 (5.50) 和式 (5.51) 成为

$$\begin{aligned} P_D &= p(p_{d1}, p_{d2}, p_{d3}) \\ &= u_0(1,1,1)p_{d1}p_{d2}p_{d3} + u_0(1,1,0)p_{d1}p_{d2}(1-p_{d3}) + u_0(1,0,1)p_{d1}(1-p_{d2})p_{d3} + \\ &\quad u_0(0,1,1)(1-p_{d1})p_{d2}p_{d3} + u_0(1,0,0)p_{d1}(1-p_{d2})(1-p_{d3}) + \\ &\quad u_0(0,1,0)(1-p_{d1})p_{d2}(1-p_{d3}) + u_0(0,0,1)(1-p_{d1})(1-p_{d2})p_{d3} + \\ &\quad u_0(0,0,0)(1-p_{d1})(1-p_{d2})(1-p_{d3}) \end{aligned}$$

$$\begin{aligned} P_F &= p(p_{f1}, p_{f2}, p_{f3}) \\ &= u_0(1,1,1)p_{f1}p_{f2}p_{f3} + u_0(1,1,0)p_{f1}p_{f2}(1-p_{f3}) + u_0(1,0,1)p_{f1}(1-p_{f2})p_{f3} + \\ &\quad u_0(0,1,1)(1-p_{f1})p_{f2}p_{f3} + u_0(1,0,0)p_{f1}(1-p_{f2})(1-p_{f3}) + \\ &\quad u_0(0,1,0)(1-p_{f1})p_{f2}(1-p_{f3}) + u_0(0,0,1)(1-p_{f1})(1-p_{f2})p_{f3} + \\ &\quad u_0(0,0,0)(1-p_{f1})(1-p_{f2})(1-p_{f3}) \end{aligned}$$

若采用 2/3 表决规则, 则

$$u_0(\mathbf{u}) = \begin{cases} 1 & u_1 + u_2 + u_3 \geq 2 \\ 0 & u_1 + u_2 + u_3 < 2 \end{cases}$$

此时,  $u_0(1,1,1) = u_0(1,1,0) = u_0(1,0,1) = u_0(0,1,1) = 1$ ,  $u_0(0,0,0) = u_0(1,0,0) = u_0(0,1,0) = u_0(0,0,1) = 0$ 。

于是融合中心的检测概率和虚警概率分别为

$$\begin{aligned} P_{D(2/3)}(p_{d1}, p_{d2}, p_{d3}) &= p_{d1}p_{d2}p_{d3} + p_{d1}p_{d2}(1-p_{d3}) + p_{d1}(1-p_{d2})p_{d3} + (1-p_{d1})p_{d2}p_{d3} \\ P_{F(2/3)}(p_{f1}, p_{f2}, p_{f3}) &= p_{f1}p_{f2}p_{f3} + p_{f1}p_{f2}(1-p_{f3}) + p_{f1}(1-p_{f2})p_{f3} + (1-p_{f1})p_{f2}p_{f3} \end{aligned}$$

### 5.3.3 不同性能传感器的全局表决检测通用模型

受 5.3.2 节融合中心检测概率  $P_D$ 、虚警概率  $P_F$  与各传感器检测和虚警概率  $p_{d_k}$ 、 $p_{f_k}$  的关系式 (5.50) 和 (5.51) 的具体案例启发, 可以将单调函数  $u_0(\mathbf{u}) = u_0(u_1, \dots, u_K)$  具体化, 从而可将不同性能传感器的全局检测概率和虚警概率表示为如下通用形式:

$$p_{D(T/K)}(p_{d1}, \dots, p_{d_K}) = \sum_{j=T}^K \sum_{C_{j/K}} \{p_{d1}, \dots, p_{d_K}\} \quad (5.53)$$

$$p_{F(T/K)}\{p_{f1}, \dots, p_{f_K}\} = \sum_{j=T}^K \sum_{C_{j/K}} \{p_{f1}, \dots, p_{f_K}\} \quad (5.54)$$

式中,

$$\sum_{C_{j/K}} \{p_{d_1}, \dots, p_{d_K}\} = \sum_{\sum u_k = j} \prod_{k=1}^K p_{d_k}^{u_k} (1-p_{d_k})^{1-u_k} \quad (5.55)$$

$$\sum_{C_{j/K}} \{p_{f_1}, \dots, p_{f_K}\} = \sum_{\sum u_k = j} \prod_{k=1}^K p_{f_k}^{u_k} (1-p_{f_k})^{1-u_k} \quad (5.56)$$

式中的  $\sum_{\sum u_k = j}$  表示对所有  $\sum u_k$  等于  $j$  的各  $u_k$  组合情况求和。

对于不同性能（虚警概率和检测概率不同）的多传感器表决检测来说，在给定传感器数量  $K$  的情况下，如何选择成功检测的传感器数（样本数） $T$ ，使得

$$p_{D(T/K)} \geq \max\{p_{d_1}, p_{d_2}, \dots, p_{d_K}\} \quad (5.57)$$

$$p_{F(T/K)} \leq \min\{p_{f_1}, p_{f_2}, \dots, p_{f_K}\} \quad (5.58)$$

也就是融合中心的全局检测效能高于任一单一传感器的检测效能，成为要解决的首要问题。对于这个问题，下述几个结论在一定程度上给出了答案。

结论 1：若  $K = 2T - 1$ ， $p_{d_k} \geq 0.5$  ( $k=1, 2, \dots, K$ )，则

$$p_{D(T/K)} \geq \max\{p_{d_1}, p_{d_2}, \dots, p_{d_K}\} \quad (5.59)$$

结论 2：若  $K = 2T - 1$ ， $p_{f_k} \leq 0.5$  ( $k=1, 2, \dots, K$ )，则

$$p_{F(T/K)} \leq \min\{p_{f_1}, p_{f_2}, \dots, p_{f_K}\} \quad (5.60)$$

特别地，此时还有下式成立：

$$p_{F(k/K)} \leq \min\{p_{f_1}, p_{f_2}, \dots, p_{f_K}\} \quad T \leq k \leq K \quad (5.61)$$

结论 3：若  $K = 2T$ ， $p_{f_k} \leq 0.5$  ( $k=1, 2, \dots, K$ )，则

$$p_{F(T/K)} = \sum_{j=T+1}^K \sum_{C_{j/K}} \{p_{f_1}, p_{f_2}, \dots, p_{f_K}\} + \frac{1}{2} \sum_{C_{T/K}} \{p_{f_1}, p_{f_2}, \dots, p_{f_K}\} \leq \min\{p_{f_1}, p_{f_2}, \dots, p_{f_K}\} \quad (5.62)$$

式中， $\sum_{C_{j/K}} \{p_{f_1}, p_{f_2}, \dots, p_{f_K}\}$  和  $\sum_{C_{T/K}} \{p_{f_1}, p_{f_2}, \dots, p_{f_K}\}$  如式 (5.56) 所示。

结论 4：若  $K = 2T$ ， $p_{d_k} \geq 0.5$  ( $k=1, 2, \dots, K$ )，则

$$p_{F(T/K)} = \sum_{j=T+1}^K \sum_{C_{j/K}} \{p_{d_1}, p_{d_2}, \dots, p_{d_K}\} + \frac{1}{2} \sum_{C_{T/K}} \{p_{d_1}, p_{d_2}, \dots, p_{d_K}\} \geq \max\{p_{d_1}, p_{d_2}, \dots, p_{d_K}\} \quad (5.63)$$

式中， $\sum_{C_{j/K}} \{p_{d_1}, p_{d_2}, \dots, p_{d_K}\}$  和  $\sum_{C_{T/K}} \{p_{d_1}, p_{d_2}, \dots, p_{d_K}\}$  如式 (5.55) 所示。

结论 1~结论 4 表明，在计数表决检测系统中，当局部成功检测的传感器数量等于或超过一半，且检测概率都大于 0.5（虚警概率小于 0.5）时，会得到比较满意的全局检测效果。这 4 个结论是不同性能传感器表决检测方法的一般结论，其证明过程见参考文献[21]。

### 5.3.4 同类传感器表决检测通用模型

当  $K$  个传感器检测性能相同时，其虚警概率均为  $p_f$ ，检测概率均为  $p_d$ 。在  $T/K$  表决检测系统中，融合中心的虚警概率和检测概率分别如式 (5.44) 和式 (5.45) 所示。此时问题 (5.57) 和式 (5.58) 变成：

$$p_{D(T/K)} \geq p_d \quad (5.64)$$

$$p_{F(T/K)} \leq p_f \quad (5.65)$$

对于这种情况下的表决检测系统( $T/K$ )，有下述几个结论成立：

结论 5：若  $K=2m+1$ ，则当  $T=m+1$  时，式 (5.64) 和式 (5.65) 成立。因此时  $K=2m+1=2T-1$ ，由上一小节结论 1 和结论 2 即知此结论正确。

结论 6：若  $K=2T$ ，当  $p_d \geq \frac{1+\sqrt{13}}{6}$ ， $p_f < 0.5$  时，有

$$\begin{aligned} p_{D(T+1/K)} &\geq p_d \\ p_{F(T+1/K)} &\leq p_f \end{aligned} \quad (5.66)$$

结论 7：若  $K=2T$ ，当  $p_f < \frac{5-\sqrt{13}}{6}$ ， $p_d > 0.5$  时，有

$$\begin{aligned} p_{D(T/K)} &\geq p_d \\ p_{F(T/K)} &\leq p_f \end{aligned} \quad (5.67)$$

结论 8：若  $K=2T-1(T \geq 3)$ ，当  $p_f < 0.125$ 、 $p_d < 0.5$  时，有

$$\begin{aligned} p_{D(T-1/K)} &\geq p_d \\ p_{F(T-1/K)} &\leq p_f \end{aligned} \quad (5.68)$$

结论 5~结论 8 给出了同类传感器表决检测的  $T$  值选择方法，具有直接的应用价值，其证明过程见参考文献[21]。

## 5.4 基于虚发现率的分布式检测门限控制

在一个检测场景中，假设在一个目标辐射信号有限感应的范围内设置的各传感器接收相同的信号，该范围之外的其他传感器不接收任何目标信号。现实中的石油或化学泄露<sup>[49]</sup>以及更常见的电磁信号或声音传播也近似于这样的盘状辐射信号模型。该模型简单并能清晰地表现此类介质的传播现象。当然，网络中的传感器可以接收不同目标（辐射源）的信号。众所周知，设计该问题的局部最优和全局最优信号检测判定规则是很困难的。早期的相关研究假设所有传感器使用相同的 LRT 局部门限进行局部判定。由于不知道辐射源（目标）和探测传感器的位置，故无法知晓每个传感器的检测概率，因此，式 (5.38) 和式 (5.39) 所示的 Chair—Varshney 融合规则无法应用于该类问题。在 5.3 节中采用了一个直觉选择，即融合中心将局部检测计数  $\sum_{k=1}^K u_k$  作为判定统计量，通过一个门限判定获取全局检测结果。这个方法可视为一级判定采用多假设检验（即每个传感器执行一个局部二元假设检验），而融合中心使用一级判定结果最终获得一个全局判定。这样一来，该两级最优检测问题就归结为局部和全局判定门限的最优组合问题。在该类问题中，术语“判定规则”和“判定门限”可交换使用。文献[50-52]给出了该类检测问题的优化方法，但需要知悉或估计局部传感器的信噪比 SNR，而这是很困难的，因为 SNR 依赖于未知的辐射目标和探测传感器的位置。文献[53]提出了一个基于虚发现率（False Discovery Rate, FDR）控制的检测模式，在不增加设计参数数量的条件下使用非独立局部传感器判定规则，该基于 FDR 的检测策略不需要局部传感器的 SNR 估计量。本节将讨论基于 FDR 模式的检测策略的一些细节。由于 FDR 以统计学



中的多假设检验（也称为多比较问题，MCP）的形式提出，下面对多比较问题进行简单回顾。

### 5.4.1 统计学中的多比较问题

多比较问题源于多联立假设检验。多个单一假设检验构成一个族检验，其效果度量采用族状态误差率（Family—Wise Error Rate, FWER）<sup>[54]</sup>，其定义为所涉及的任一 I 型误差或虚警概率，描述如下：若每个局部检验误差率是  $\alpha$ ，则作为  $K$  个单一检验构成的族检测的 FWER 定义为

$$\alpha_F = P(V \geq 1) = 1 - (1 - \alpha)^K \quad (5.69)$$

式中的  $V$  为虚警数。从该式可以看出，对于一个单一比较来说， $\alpha_F = \alpha$ 。当比较数增多， $\alpha$  不变，而  $\alpha_F$  随之增加。这就是经典多比较过程的一个基本问题，目的是通过单一检测误差率  $\alpha$  和数量  $K$  控制族检测状态误差率  $\alpha_F$ 。控制 FWER 的一个方法是 Bonferroni 过程，它依据 Bonferroni 不等式，即多事件的并集的概率小于或等于各单一概率值之和：

$$P(A_1 \cup A_2 \cup \dots \cup A_K) \leq \sum_{k=1}^K P(A_k) \quad (5.70)$$

由于  $\alpha_F = 1 - (1 - \alpha)^K \leq \alpha K$ ，即  $\alpha \geq \alpha_F / K$ ，若各单一检验皆以虚警率  $\alpha^* = \alpha_F / K$  实现，该族检验的 FWER 就能保持在  $\alpha_F$  上，但该过程过于保守，因为此时各单一检验虚警率  $\alpha^* \leq \alpha$ ，即虚警减少，从而导致各单一检验的检测概率（功效）减少。文献[55]提出一个完全不同且更公平的方法来进行 FDR 控制，它将 FDR 定义为拒绝假设（ $H_0$ ）中的虚假拒绝（宣布为  $H_1$ ）部分。对于两假设  $H_0$  和  $H_1$  的二元假设检验问题，表 5.2 定义了一些术语，以引出 FWER 和 FDR 的定义。

表 5.2 定义 FDR 的一些术语

	宣布为 $H_0$	宣布为 $H_1$	总 数
$H_0$ 为真	$U$	$V$	$K_0$
$H_1$ 为真	$T$	$S$	$K - K_0$
总数	$K - R$	$R$	$K$

基于表 5.2，FDR 定义为虚警（ $H_0$  为真时，宣布为  $H_1$ ）数与检测总数（由为真和为虚的检测数组成）之比的期望值

$$Q_E = E(Q) \quad (5.71)$$

式中，

$$E(Q) = \begin{cases} \frac{V}{V+S} & V+S \neq 0 \\ 0 & V+S = 0 \end{cases} \quad (5.72)$$

文献[55]就是基于这个度量标准，提出了多比较问题的 FDR 控制算法。

### 5.4.2 基于 FDR 局部门限控制的全局优化检测算法

设  $P_1, P_2, \dots, P_K$  是  $K$  元检验的  $P$ -值，一个传感器观测集合  $S_k$  的  $P$ -值定义为

$$P(k) = \int_{S_k}^{\infty} f_0(s) ds \quad k=1,2,\dots,K \quad (5.73)$$

式中,  $f_0(s) = f_0(s/H_0)$  是假设  $H_0$  (目标不出现) 之下的观测  $S$  的条件密度, 即条件似然函数, 而  $P(k)$  表示基于  $S_k$  单一假设检验的虚发现率 FDR。控制各传感器 FDR 低于一个值  $\gamma$ , 并使该  $K$  元全局检测 FDR (即 FWER) 低于  $\gamma$  的控制过程称为 Benjamini—Hockberg 过程, 该控制过程如下<sup>[55]</sup>:

① 计算所有  $K$  个传感器测量集合  $S_k$  的  $P$ -值:  $P_1, P_2, \dots, P_K$ , 将其排序为

$$P(1) \leq P(2) \leq \dots \leq P(K)$$

② 求取  $d = \arg \max_k \{P(k) \leq k\gamma / K\}$ , 其中  $\gamma$  为每个传感器的 FDR 门限值。

③ 宣布  $P(k)$  ( $k=1,2,\dots,d$ ) 对应的观测判定结论为  $H_1$ 。

文献[55]证明, 在假设  $H_0$  为真时, 在各传感器检测统计量相互独立的情况下, 基于  $P(k)$  值的上述控制过程将每个传感器的虚发现率 (FDR) 控制为  $\gamma$  (我们注意该控制过程的结论是测量  $S_1, S_2, \dots, S_d$  皆为虚警)。

文献[56]证明, 当融合中心的全局检验统计量反向依赖于真的  $H_0$  假设对应的各传感器检验统计量时, 该过程也能控制全局的 FDR 为  $\gamma$ 。该控制过程寻找满足  $P(l) \leq l\gamma / K$  最大的  $l$ , 目的是在各传感器  $FDR \leq \gamma$  的情况下, 使全局检测虚警达极大,  $P_F = d / K$  (见上述控制过程的步骤③), 从而产生最大的全局检测概率。还需注意的是, 假设  $H_1$  为真 (零虚警) 时, 各传感器检测统计量相互独立的假设不需要理论证明。

文献[56]给出的该传感器 FDR 控制过程需进行  $P$ -值排序, 该排序通常由融合中心集中进行。对于前面描述的分布式表决检测问题, 各传感器仅将 1 比特代码传送给融合中心。此时需要预先确定各传感器的一个分布式排序模式, 以使融合中心基于步骤②知道各传感器的 FDR 门限。文献[55]提出一个分散式 FDR 控制过程, 其中每个传感器仅需 1 比特的通信负荷就能够达到与上述 Benjamini—Hockberg 过程同样的控制能力, 显然此时网络的最大通信负荷小于或等于  $K$  比特 ( $K$  为网络中传感器总数)。

上述基于 FDR 控制的一个重要性质是:

**命题 5.1** 若所有多比较问题 (MCP) 都有假设  $H_0$  为真, 即  $K_0 = K$ , 则每个传感器的 FDR 控制等价于 FWER 控制。若只有某些 MCP 假设  $H_1$  为真, 即  $K_0 < K$ , 则单一检验 FDR 控制门限小于全局 FWER 控制门限。

该命题在假设  $H_1$  为真的情况下, 采用各传感器单一检验的 FDR 控制比采用全局 FWER 控制更公平。这是由于全局 FWER 控制将各局部 FDR 控制为相同的门限  $\alpha = \alpha_F / K$ , 这限制了局部虚警概率  $P_F$  的增加, 从而限制了检测概率的增加; 而采用传感器 FDR 控制, 局部检测概率会随着假设  $H_1$  为真的数量增加而增加。此外, 从上述 FDR 控制过程步骤②可以看到, FDR 控制会产生关于拒绝  $H_0$  (判定  $H_1$ ) 门限的一个变化数据 (指  $P$ -值门限  $d$ ), 它可能随  $H_1$  为真的数量而增加, 不像传统统计检验中的拒绝  $H_0$  区域是一个固定的先验值。FDR 控制的这个动态特性成为设计分布式检测局部判定门限以实现 FDR 控制的主要原因。

### 5.4.3 基于 FDR 的分布式检测系统设计

从 5.4.1 节关于多比较问题 (MCP) 的讨论可以看出, 如果  $K$  个传感器使用一个相同的判定门限  $\tau$  或  $Q(\tau)$  的  $P$ -值门限 (这里  $Q(\tau)$  服从标准高斯分布), 则全局 FWER 在所有状况下都受控于一个门限值  $KQ(\tau)$  的值。从 5.4.2 节关于 FDR 控制模式的讨论可以看出, 当关注区域 ROI 中不存在目标, 即所有 MCP 假设  $H_0$  为真时, 一个基于 FDR 的门限 (采用 FDR 参数  $\gamma$ ) 选择模式会对全局 FWER 实现基于参数  $\gamma$  的门限控制。因此, 在不存在目标时, 可以设计一个基于局部检测的 FDR 模式, 以在任意水平上控制全局 FWER。但是, 当目标出现时, 在容许较多的局部检测的情况下, 各传感器采用相同门限模式更宽松, 但要以较高的 FWER 为代价。然而, 随着一个目标的出现, FDR 控制模式的传感器探测范围中的检测总数 (无论是真实的还是虚假的局部检测) 会比相同门限模式大大增加。因此, FDR 控制模式能够比 FWER 控制模式更好地分离 ROI 中目标不出现 ( $H_0$  为真) 与目标出现 ( $H_1$  为真) 之下的检测计数的概率质量函数 (Probability Mass Function, PMF), 也就是说, 对各传感器采用不同门限控制的 FDR 模式时, 在假设  $H_0$  为真和假设  $H_1$  为真之下 ROI 中检测计数 PMF 之间的距离大于各传感器采用相同门限控制的 FWER 模式时在假设  $H_0$  为真和假设  $H_1$  为真之下产生的 ROI 检测计数 PMF 之间的距离。在应用中, 通常将 PMF 距离量化为偏差系数来表示。这样一来, 在假设  $H_0$  为真和  $H_1$  为真的情况下, 以 ROI 中检测计数的 PMF 距离来判定检测结果 (目标出现与否) 时, 不同门限的 FDR 控制模式将优于相同门限的 FWER 控制模式。

按照前面的讨论, 基于 FDR 门限控制分布式检测系统的两个设计参数是局部传感器判定门限 (FDR 的  $\gamma$ ) 和全局判定门限  $T$ , 对于离散的全局检验统计量, 还有第 3 个统计参数即随机常数 (反映门限值附近的判定不确定性)。对于任一观测计数  $\Delta \in Z$  ( $Z \in [0, 1, \dots, K]$ ), 融合中心二元假设检验问题是:

$$\begin{aligned} G_0: P(\Delta = i; G_0) &= P_0(\Delta) \quad \text{目标不出现} \\ G_1: P(\Delta = i; G_1) &= P_1(\Delta) \quad \text{目标出现} \end{aligned} \quad (5.74)$$

如果  $T(\Delta)$  是判定统计量, 则 NP 准则下的最优检验可以采用如下概率  $\delta_T(\Delta)$  来判定选择假设  $H_1$ :

$$\delta_T(\Delta) = \begin{cases} 1 & \text{若 } T(\Delta) > T & H_1 \text{ 为真} \\ \kappa & \text{若 } T(\Delta) = T & \text{不定} \\ 0 & \text{若 } T(\Delta) < T & H_0 \text{ 为真} \end{cases} \quad (5.75)$$

式中,  $T$  是全局判定门限;  $\kappa$  是随机参数, 表示检测门限  $T$  附近所出现的不确定性;  $T(\Delta)$  是似然比 (如式 (5.14) 或式 (5.26) 所示, 可由各传感器局部似然比之积获得)。

为避免最优 NP 检测的复杂性, 可以认为检测统计量  $T(\Delta) = \Delta$ , 此时融合中心虚警概率和检测概率分别为

$$P_F = P(\Delta > T; G_0) + \kappa P(\Delta = T; G_0) \quad (5.76)$$

$$P_D = P(\Delta > T; G_1) + \kappa P(\Delta = T; G_1) \quad (5.77)$$

对于给定 FDR 门限的传感器检测, 融合中心的检测门限  $T$  和  $\kappa$  可通过约束其虚警率  $P_F$

来选择,  $P_F$  与门限  $T$  和随机常数  $\kappa$  之间的关系式是:

$$P_F = \sum_{k=T+1}^K \binom{K}{k} (1-\gamma) \left(\frac{k\gamma}{K}\right)^k \left(1-\frac{k\gamma}{K}\right)^{K-k-1} + \kappa \binom{K}{T} (1-\gamma) \left(\frac{T\gamma}{K}\right)^T \left(1-\frac{T\gamma}{K}\right)^{K-T-1} \quad (5.78)$$

对任意给定的传感器 FDR 门限  $\gamma$ , 融合中心门限  $T$  和随机常数  $\kappa$ , 融合中心检测概率是<sup>[53]</sup>:

$$P_D = \sum_{k=T+1}^K P(\Delta=k; G_1) + \kappa P(\Delta=T; G_1) \quad (5.79)$$

式中,  $P(\Delta=k; G_1)$  表示一个目标出现在 ROI 中, 观测计数为  $k$  的概率。当传感器较多 (即  $K$  较大) 时, 融合中心的检测概率可通过下式近似得到:

$$P_D = Q \left[ \frac{T - K\bar{p}_d}{\sqrt{K\bar{p}_d(1-\bar{p}_d)}} \right] \quad (5.80)$$

式中,  $\bar{p}_d$  是一个传感器的平均检测概率。这里  $Q(\tau)$  服从标准高斯分布, 即

$$Q(\tau) = \frac{1}{\sqrt{2\pi}} \int_{\tau}^{\infty} e^{-\frac{\xi^2}{2}} d\xi, \text{ 门限 } \tau = \frac{T - K\bar{p}_d}{\sqrt{K\bar{p}_d(1-\bar{p}_d)}} \text{ 是融合中心计数门限 } T \text{ 对输入的 } K \text{ 个传感器}$$

平均计数  $K\bar{p}_d$  的偏差系数。

为了使融合中心的全局检测性能达到最优, 选择各传感器的最优检测门限  $\gamma$  是一个极其困难的问题。借助接收机运行特征 (ROC) 的优化过程获得最佳的  $\gamma$  或  $\tau$  要付出过高的运算代价。一个计算量较小的求取一个传感器最优检测门限的方法是借助优化偏差系数来获得, 因为在高斯假设下, 极大化偏差系数会使通过 ROC 表示的检测性能达极大。然而, 在非高斯条件下却不存在较大的偏差系数能达到 ROC 曲线的最佳性能这一通用结论。但直觉表明, 此时增加偏差系数通常意味着  $P(\Delta; G_0)$  和  $P(\Delta; G_1)$  之间的距离增大, 因此很可能产生最佳的传感器设计选择。这样一来, 我们可以将一个传感器检测的 FDR 参数  $\gamma$  设置为使偏差系数达极大的一个值。基于 FDR 检测门限控制模式与基于 FWER 采用相同检测门限控制模式所产生的融合中心检测性能的比较如图 5.5 所示, 从中可以看出, 基于 FDR 的检测方法比传统相同门限检测方法在全局检测性能上有重大改善。




图 5.5 基于 FDR 检测门限控制模式与基于 FWER 采用相同检测门限控制模式的全局检测性能比较

## 5.5 相关情况的分布式检测

分布式检测系统的一个重要结论是：对于经典检测框架，在给出的每个假设下，若各传感器观测是条件独立的，则各局部传感器的似然比（LRT）判定是最优的<sup>[17]</sup>。这个性质大大缩减了搜索各局部检测规则的最优组合的空间范围。尽管产生的问题未必很容易解决，却适用于多种关系分析。通常，若不确定性主要来自于探测装置和环境噪声，则假设各传感器节点的条件独立性是合理的。然而，这一点对任意的传感器系统未必都能适用，例如，当一个传感器与其他传感器很接近时（此时两接近的传感器就像是一个传感器），它们对同一目标的观测在时间和观测数据上很接近，因此这些测量是强相关的（好像来自一个传感器观测报告两次）。如果观测信号具有随机性或各传感器受共同外部噪声作用，则各传感器观测的条件独立假设也可能失效。若没有条件独立假设，本章前面诸节所进行的分布式检测问题的许多分析和结论，如诸多公式中多传感器联合观测密度等于各传感器各边缘观测密度之积、融合中心的似然比等于各传感器局部似然比之积等都难以成立，这就使得多传感器系统的最优检测无法表示为完全依赖于各单一传感器 LRT 的门限检测形式，这样一来就难以寻找分布式检测的最优解<sup>[15]</sup>。

### 5.5.1 基于相关观测的最优分布式检测研究现状

当前，对于相关条件下分布式检测问题的研究主要集中在似然比检验（LRT）范围内，采用各种算法来确定这个限定集合内的最优解，以使产生的分布式检测系统能够达到可接受的应用性能。文献[57]介绍了相关噪声中的已知和未知信号的检测问题的研究现状，主要成果有：

在文献[58]中，Chen 和 Papamarcou 针对两个传感器观测在高斯分布下的数据漂移情况，导出了每个传感器局部 LRT 判定最优性的充分条件。

在文献[59]中，Aalo 和 Viswanathan 设定多传感器各个局部 LRT 判定，并研究相关噪声对分布式检测系统的影响，该 LRT 检测考虑附加高斯和拉普拉斯噪声的已知信号。当相关噪声增加时，系统性能恶化。

文献[60]考虑了两个相关模型，一个模型是任意两个传感器之间的相关系数随它们之间的间隔增加而减小，另一个模型是任意两个传感器之间的相关系数是常数，并考察了当传感器数量无限增加时采用高斯噪声所产生的渐进 LRT 检测性能。

在文献[61]中，Blum 等人研究了相关的非噪声中的已知信号的分布式检测问题，其中将噪声视为是圆形对称的。

在文献[62]中，Lin 和 Blum 观察了相关的  $t$  分布噪声中已知信号的两传感器分布检测问题。仿真表明，在某些特定情况下采用不同的局部判定规则比 LRT 判定规则的效果要好。

文献[63]从一个数字视图角度探索了观测相关时的一个分布式  $M$  元假设检验问题。

在文献[64]中，Willett 等人研究了带有依赖性的高斯观测的两检测器情况，可以看作是

最简单的、有意义的问题之一,他们发现,每个局部判定规则的形态可能很复杂。

最近的研究成果文献[65]提出在有条件的依赖性观测下构建一个层次性条件独立模型的分布式检测的新框架,该推荐模型通过在传感器观测中引入产生条件独立的隐式变量,将分布式检测与依赖性观测和独立性观测统一起来。

### 5.5.2 基于相关局部判定的最优分布式检测研究现状

对于基于相关观测的检测问题,还可以通过将局部传感器判定规则限制为次优二元量化装置,融合中心在设计检测规则时,考虑各局部判定的相关性,以改善全局检测性能。迄今为止,基于相关传感器局部判定的全局融合规则设计研究主要有:

在文献[66]中,Drakopoulos 和 Lee 开发了基于相关判定的 NP 准则的一个最优融合规则,在假设各传感器判定之间的相关系数是已知的条件下,给出了产生各相关判定的局部传感器门限。其中采用一个专用相关结构,研究了依赖于相关程度的系统检测性能,并且证明了采用较多数量传感器所获得的检测性能随各局部判定之间的相关程度增长而退化。

在文献[67]中,采用概率密度函数(PDF)的 Bahadur—Lazarsfeld 级数展开式导出基于各相关局部判定的最优融合规则。使用该级数展开式,局部相关的二元判定的 PDF 可以采用相关因素的各独立随机变量的 PDF 之积来表示。在许多实际情况中,超出一个确定等级的条件相关系数可以假设为零,这样,最优融合规则的计算就变得容易了。当所有条件相关系数皆为零时,最优融合规则就简化为 Chair—Varshney 规则。这里,融合规则的实现要假设传感器观测的联合密度是多变量高斯分布(各单一传感器观测也是高斯分布的),在协方差矩阵中各传感器线性依赖性采用皮尔逊相关系数。

### 5.5.3 进一步说明

在许多应用中,传感器观测之间的依赖性采用多种不同的线性形式表示,不止皮尔逊相关系数一种,这就需要更通用的相关性描述[68]。此时,表示各传感器观测的统计量边缘分布也可以是不独立的。需要强调的是,对任意边缘密度(或质量)函数来说,多变量密度(或质量)函数并不一定存在,换句话说,给出任意边缘分布密度并不能以某种方式表示出其联合分布密度。

需要说明的另一点是多传感器相关判定的融合方法并不一定需要各传感器观测或判定的联合统计量信息,这是当前运用连结理论(Copula Theory)产生的新方法<sup>[69]</sup>。连结理论在经济和金融领域已有普遍应用,但在信号处理领域的应用刚刚开始。文献[70,71],对含有相关观测和异类传感器观测一个共同场景的信号检测问题采用连结理论,其中对于相关判定的融合来说,不需要各传感器观测或判定的联合统计量的先验信息,而是基于一个连接选择过程构造该联合统计量。需指出的是,若使用一个具体参数的连结函数所构建的多传感器观测或判定的联合分布不能充分模拟各传感器潜在的联合分布,则基于连结函数的融合判定规则无法获得比 Chair—Varshney 规则更好的分布式检测结果。因此,必须尝试选择连结函数,分布式检测问题连结函数的选择在文献[72]中有专题介绍。

## 5.6 非理想通信信道下的分布式检测

### 5.6.1 概念与模型

采用高信噪比 (SNR) 和有效的信道误差校验代码的通信系统具有很低的误码率和很少的时间延误, 通常称为理想通信信道。在分布式检测系统中, 理想通信信道可假设能够实现无损传输, 即各传感器局部判定能够及时、无误差地传输到融合中心。在 WSN 中, 该无损传输假设则需要仔细推敲, 因为在严格的 WSN 资源限制下, 增加传输功率和使用有效的误差校验代码并不总是可行的。此外, 在一个电磁对抗环境中, 传输信号的功率必须保持最低才能达到较低的被截获/被检测概率 (Low Probability of Intercept/ Low Probability of Detection, LPI/LPD), 从而实现隐蔽通信。这样一来, 在许多情况就必须容许在一定范围内的数据传输损失。在分布式检测系统中, 为了克服或减少这个损失, 需要采用把通信传输与融合判定功能灵活地集成到一起的运行模式, 在不额外消耗外部系统资源情况下达到一个令人满意的系统性能。于是, 人们开始研究在融合中心如何对由于传输过程信道衰减和噪声干扰而恶化的各局部判定进行融合的问题。

衰减和噪声信道衰减下的一个分布式并行检测模型如图 5.6 所示, 其中各传感器局部检测结果为  $u_k$  ( $k=1,2,\dots,K$ ), 它们通过独立衰减的并行信道传输给融合中心。我们在这里考虑一个离散时间按瑞利分布比例衰减的信道, 该信道在第  $k$  个传感器与融合中心之间具有一个稳态和各态历经的复数增益  $h_k e^{j\varphi_k}$ , 这里  $h_k$  和  $\varphi_k$  分别表示该信道的衰减幅度包络线和相位。

图 5.6 中,  $u_k$  是第  $k$  个传感器生成的局部二元判定,  $h_k$  是该衰减信道的增量,  $n_k$  是零均值、方差为  $\sigma^2$  的高斯随机噪声,  $y_k$  是融合中心接收到的第  $k$  ( $k=1,2,\dots,K$ ) 个传感器的检测结果, 由于信道衰减和噪声干扰,  $y_k$  已不是二值布尔变量。图 5.6 中还假设信道增量在一个

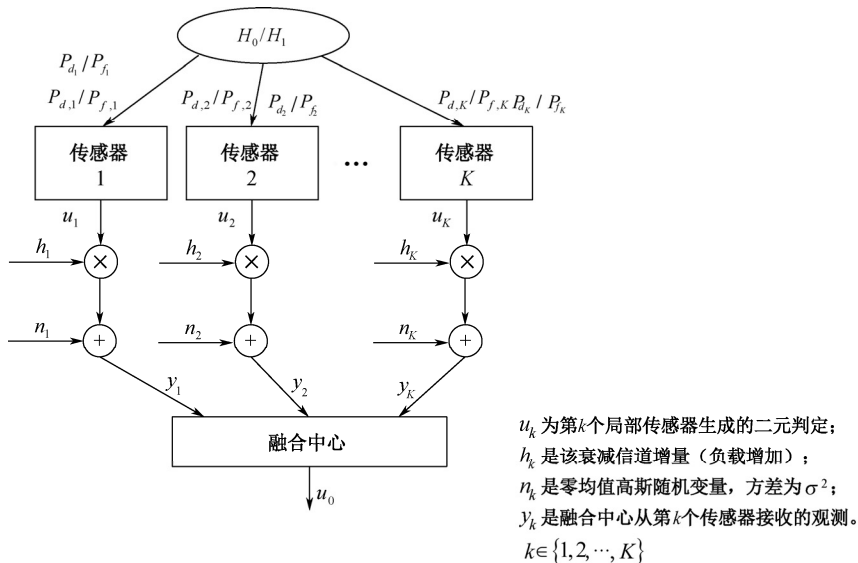


图 5.6 衰减和噪声信道下的分布式并行检测模型

局部判定传输过程中保持不变,并且信道是相互独立的。为进一步简化分析,我们假设传输二进制信号,并且用  $s_k \in \{-1,1\}$  代替  $u_k \in \{0,1\}$ 。这样一来,信道衰减的影响就化为相参接收的实部数量积。该相参接收可以通过对稳态信道的有限训练或者以一个小的 SNR 降低为代价,对快速衰减信道采用来自相同信号模型的不同编码来达成。融合中心接收的传感器信号模型表示为

$$\tilde{y}_k = h_k e^{j\phi_k} s_k + v_k \quad (5.81)$$

式中,  $v_k$  是一个零均值复数高斯噪声,具有相同方差  $\sigma_n^2$  的独立实部和虚部,即  $\mathbf{CN}(0, 2\sigma_n^2)$ , 这里符号  $\mathbf{CN}$  表示复高斯分布。我们假设带有单位功率的瑞利衰减信道,即  $h_k e^{j\phi_k} \sim \mathbf{CN}(0,1)$ , 从而  $E(h_k^2)=1$ 。利用接收机信道相位知识,能够获得融合中心对第  $k$  个传感器的观测模型:

$$y_k = h_k s_k + n_k \quad (5.82)$$

由于式(5.81)中的  $v_k$  服从一个圆形对称的复高斯分布,故这里的噪声项实部  $n_k \triangleq \text{Re}\{v_k e^{-j\phi_k}\}$  是带有方差  $\sigma_n^2$  的高斯白噪声,即  $n_k \sim N(0, \sigma_n^2)$ 。

### 5.6.2 考虑信道衰减的分布式检测规则

这里列出迄今为止信道衰减下几个主要的分布式检测规则。

#### ① 基于最优似然比的融合检测规则。

文献[73]在给出信道衰减瞬时状态知识、传感器局部检测性能指标  $P_{d_k}$  和  $P_{f_k}$  ( $k=1,2,\dots,K$ ) 的情况下,导出了基于最优似然比(LR)的分布式检测规则。其中融合检测的对数似然比统计量可由下式给出:

$$\begin{aligned} A(\mathbf{y}) &= \ln \left[ \frac{p(\mathbf{y} | H_1)}{p(\mathbf{y} | H_0)} \right] \\ &= \sum_{k=1}^K \ln \left[ \frac{P_{d_k} \exp[-(y_k - h_k)^2 / 2\sigma_n^2] + (1 - P_{d_k}) \exp[-(y_k + h_k)^2 / 2\sigma_n^2]}{P_{f_k} \exp[-(y_k - h_k)^2 / 2\sigma_n^2] + (1 - P_{f_k}) \exp[-(y_k + h_k)^2 / 2\sigma_n^2]} \right] \end{aligned} \quad (5.83)$$

式中,  $\mathbf{y} = [y_1, y_2, \dots, y_K]^T$  是融合中心从所有  $K$  个传感器接收的局部检测向量。需要注意的是,这个融合检测规则需要知悉各局部传感器性能指标和瞬时信道状态信息(CSI)。文献[73]中还提出了放宽先验知识需求的次优融合检测规则。文献[74]中导出了给定信道状态精确信息和两假设下各传感器条件独立情况下基于最优 LRT 的融合统计量的概率分布。

#### ② Chair—Varshney 融合检测规则。

文献[73]中还给出了 Chair—Varshney 融合次优检测统计量<sup>[25]</sup>,它是对式(5.83)给出的对数似然比统计量的一个高信噪比近似:

$$A_1 = \sum_{\text{sign}(y_k)=1} \ln \frac{P_{d_k}}{P_{f_k}} + \sum_{\text{sign}(y_k)=-1} \ln \frac{1 - P_{d_k}}{1 - P_{f_k}} \quad (5.84)$$

这里的  $A_1$  不需要关于传输信道的任何知识,仅需知道各局部传感器的  $P_{d_k}$  和  $P_{f_k}$  ( $k=1,2,\dots,K$ )。该次优方法容许低于适当的 SNR 之下出现的效能损失。文献[75]给出了对检测性能分析的很有帮助的 Chair—Varshney 统计量的分布。

#### ③ 极大比组合(Maximum Ratio Combining, MRC)融合次优检测规则。



文献[73]指出, 对于信道信噪比 (SRN) 较低的情况, 式 (5.83) 可简化为

$$A_2 = \frac{1}{K} \sum_{k=1}^K (P_{d_k} - P_{f_k}) h_k y_k \quad (5.85)$$

如果进一步假设每个传感器局部检测性能相同, 即  $P_{d_k} = P_d$ ,  $P_{f_k} = P_f$  ( $k = 1, 2, \dots, K$ ) 则融合检验统计量还可以简化为类似于一个极大比组合 (MRC) 统计量的形式:

$$A_2 = \frac{1}{K} \sum_{k=1}^K h_k y_k \quad (5.86)$$

该式中, 不需要知道  $P_d$  和  $P_f$ , 只需要  $P_d - P_f > 0$ , 并且需要知道信道增益。

④ 等增益组合 (Equal Gain Combining, EGC) 融合次优检测规则。

受  $A_2$  的各种 MRC 统计量的启发, 提出了第三种可选形式, 即等增益组合 (EGC), 它需要的信息量最少:

$$A_2 = \frac{1}{K} \sum_{k=1}^K h_k y_k \quad (5.87)$$

值得充分关注的是, 在一个较大的信噪比 SNR 范围内,  $A_3$  的检测性能优于  $A_1$  和  $A_2$  [73]。

### 5.6.3 基于部分信道状态的分布式检测

式 (5.83) 给出的基于最优 LRT 的融合检测规则需要 WSN 中所有传感器的瞬时信道状态信息  $h_k$  和  $\Phi_k$ 。然而, 对具有有限资源 (能量和带宽) 的 WSN 来说, 必须抑制所耗费的资源, 包括估计每个时间局部传感器将其检测发送给融合中心对信道的占用量 (引起的信道增量)。于是, 可以强制取消信道估计并尽可能以相对小的性能降低为代价来节省资源, 这就是开发不需要瞬时估计信道增量的新的融合检测规则的深层次原因。在许多 WSN 场景中, 衰减的 (随机的) 信道统计量和附加的高斯噪声可以预先估计并作为先验信息。这样, 我们就可以使用信道统计量的先验信息代替瞬时信道状态估计信息, 开发一个新的基于 LRT 的融合检测规则。

注意式 (5.82) 以及用  $s_k \in \{-1, 1\}$  代替二元判定  $u_k \in \{0, 1\}$ , 在假设  $H_j$  的情况下, 下式成立:

$$\begin{aligned} p(y_k | H_j) &= \sum_{u_k} [p(u_k | H_j) p(y_k | s_k)] \\ &= P(u_k = 1 | H_j) p(y_k | s_k = 1) + P(u_k = 0 | H_j) p(y_k | s_k = -1) \end{aligned} \quad (5.88)$$

以及

$$p(y_k | s_k) = \int_0^\infty p(y_k | h_k, s_k) p(h_k) dh_k \quad (5.89)$$

采用设定的单位功率 (即  $E[h_k^2] = 1$ ) 的瑞利衰减信道, 其中  $h_k$  的概率密度函数是:

$$p(h_k) = 2h_k e^{-h_k^2} \quad h_k \geq 0 \quad (5.90)$$

以及

$$p(y_k | h_k, s_k) = \frac{1}{\sqrt{2\pi\sigma_n}} \exp\left(-\frac{(y_k - h_k s_k)^2}{2\sigma_n^2}\right) \quad (5.91)$$

于是, 可将基于信道统计量知识和局部检测性能指标的对数似然比 (LLR) 表示为<sup>[75]</sup>

$$\begin{aligned} \Lambda_4 &= \ln \left[ \frac{f(\mathbf{y} | H_1)}{f(\mathbf{y} | H_0)} \right] \\ &= \sum_{k=1}^K \ln \left\{ \frac{1 + \left[ P_{d_k} - Q(ay_k) \right] \sqrt{2\pi} ay_k e^{(ay_k)^2/2}}{1 + \left[ P_{f_k} - Q(ay_k) \right] \sqrt{2\pi} ay_k e^{(ay_k)^2/2}} \right\} \end{aligned} \quad (5.92)$$

采用该统计量的 LRT 检测规则称为 LRT—CS 规则, 即具有部分信道统计量 (CS) 的 LRT 规则, 其中  $a = 1/(\sigma_n \sqrt{1 + 2\sigma_n^2})$ 。

图 5.7 给出了瑞利衰减信道下 5.6.2 节所述的几个融合统计量的检测性能曲线以及本节的 LRT—CS 规则的检测性能曲线, 其中  $K=8$ ,  $P_{d_k}=0.6$ 、 $P_{f_k}=0.05$ , 从图中可以看出: 基于最优 LRT 的融合规则提供了最佳检测性能, 但它需要信道的瞬时增益。从另一角度看, 其性能可以通过具有部分信道知识的 LRT 融合规则 (LRT—CS) 精确逼近。该 LRT—CS 融合规则的性能比需要瞬时信道增益的最优 LRT 的融合规则差一些, 但比 3 个次优模式的检测性能要好。




图 5.7 SNR=4 dB 的瑞利衰减信道下几个融合统计量的检测性能曲线

#### 5.6.4 具有非信道状态信息的分布式检测

获取传输信道的相位信息可能需要较高的代价, 通常需要额外训练。对于含有移动传感器或融合中心不断运动的松散 WSN, 随时间变化选择衰减信道具有重要意义。但对于一般情况, 并不需要准确、实时的信道相位信息。因此, 文献[76]中引入了基于松散检测的判定融合规则。在松散情况下, 融合统计量仅依赖于接收到的包络或等价的从每个传感器接收的

信号功率，这就是本节所说的非信道状态信息。令  $r_k = |y_k|^2$ ，给出信道包络信息  $h_k$ ，第  $k$  个信道输出的信号功率是：

$$\begin{aligned} P(r_k | h_k, u_k = 0) &= \frac{1}{2\sigma_n^2} \exp\left(-\frac{r_k}{2\sigma_n^2}\right) \\ P(r_k | h_k, u_k = 1) &= \frac{1}{2\sigma_n^2} I_0\left(\frac{h_k}{\sigma_n^2} \sqrt{r_k}\right) \exp\left(-\frac{h_k^2 + r_k}{2\sigma_n^2}\right) \end{aligned} \quad (5.93)$$

式中， $I_0(\cdot)$  是第 0 阶修正的第一类贝塞尔函数。给出如等式 (5.90) 和式 (5.91) 所示的瑞利衰减信道的  $P(h_k)$ ，得到：

$$\begin{aligned} p(r_k | u_k = 0) &= \frac{1}{2\sigma_n^2} \exp\left(-\frac{r_k}{2\sigma_n^2}\right) \\ p(r_k | u_k = 1) &= \frac{1}{1 + 2\sigma_n^2} \exp\left(-\frac{r_k}{1 + 2\sigma_n^2}\right) \end{aligned} \quad (5.94)$$

此时能够给出作为融合检测统计量的如下对数似然比 (LLR)：

$$\begin{aligned} \Lambda(\mathbf{r}) &= \ln \left[ \frac{p(\mathbf{r} | H_1)}{p(\mathbf{r} | H_0)} \right] \\ &= \sum_{k=1}^K \ln \left[ \frac{P_{d_k} \frac{1}{1 + 2\sigma_n^2} \exp\left(\frac{-r_k}{1 + 2\sigma_n^2}\right) + (1 - P_{d_k}) \frac{1}{2\sigma_n^2} \exp\left(\frac{-r_k}{2\sigma_n^2}\right)}{P_{f_k} \frac{1}{1 + 2\sigma_n^2} \exp\left(\frac{-r_k}{1 + 2\sigma_n^2}\right) + (1 - P_{f_k}) \frac{1}{2\sigma_n^2} \exp\left(\frac{-r_k}{2\sigma_n^2}\right)} \right] \end{aligned} \quad (5.95)$$

对于已知衰减统计量的情况，文献[76]考虑了 Ricean 和 Nakagami 衰减信道。我们在本节中只研究了单跳网络具有不同程度的信道状态信息的信道察觉判定融合算法<sup>[73-76]</sup>。扩展到多跳 WSN 的相关研究可以在文献[77,78]中找到，而最优信道局部量化设计方法在文献[79-81]中进行了阐述。为了抵消传感器或信道失效，文献[82]给出了健壮二元定量设计。基于信道察觉的分布式检测正被广泛应用于协作中继网络领域的研究。

## 5.7 本章小结

本章总结并深入探讨了多传感器分布检测的概念、方法和实现技术。5.1 节描述了传统分布式检测产生的背景以及二元并行分布式检测结构和两假设似然比判定原理。其中假设各传感器相互独立运行且性能指标是已知的，并且传感器与融合中心之间的通信信道是理想的。在这些假设下，5.2 节建立了基于似然比统计量的贝叶斯准则和 NP 准则之下的融合中心全局最优判定融合规则和各传感器局部最优判定规则模型以及最优融合逻辑，同时还给出了似然比统计量的概率分布模型。对于一个由多个被动传感器组成的无线传感器网络的最优检测问题，由于目标信号位置和传感器位置是未知（或运动）的，因此各传感器性能可能并不相同且难以估计其性能指标，此外，将传感器性能信息传输到融合中心要付出较高的代价。为了解决这一问题，5.3 节介绍的基于计数的判定规则是一个非常直观的表决方法，融合中

心采用各传感器报告的判定结果中“1”的总数作为判定统计量,此时每个传感器只需要传输1个比特的局部判定结果(“0”或“1”),信道总负荷只有 $K$ 比特。5.3节还给出了各传感器基于自身独立观测进行的检测,各传感器性能不同,主要指各传感器的虚警概率 $P_{f_k}$ 和检测概率 $P_{d_k}$ 不同情况下,关于融合中心的统计计数表决检测的4个通用结论,这些结论表明,在计数表决检测系统中,若局部成功检测的传感器数量等于或超过一半,且它们的局部检测概率都大于0.5(或局部虚警概率小于0.5),就会得到满意的全局检测效果(或容许的虚警概率)。

对于同类传感器(即性能相同或各传感器的 $P_{f_k}$ 和 $P_{d_k}$ 都相同),本章也给出了4个结论,它们提出了同类传感器统计计数表决检测的门限的选取方法,以获得满意的全局检测结构,具有直接的应用意义。

5.4节基于统计学的多比较理论,给出了基于虚发现率(FDR)的传感器局部检测门限和融合中心全局检测门限的控制方法。实验表明,基于FDR门限控制的分布式检测性能比各传感器相同检测门限的方法有重大改善。5.5节向读者介绍了相关即相互依赖情况(包括各传感器量测相关和判定相关两种情况)的分布检测的研究现状,并给出了相应的参考文献。

在一个带有能量、带宽和传输延迟约束的WSN中,由于无误差传输需要高功率、大带宽和有效的误差校验代码,因此采用理想的无误差信道将各传感器判定传输到融合中心显然是不现实的。5.6节讨论了非理想信道对分布式检测性能的影响,即考虑信道衰减之下的分布式检测系统,包括建立了衰减和噪声信道下的分布式并行检测模型和几个主要的最优和次优检测规则以及具有部分信道状态信息和具有非信道状态信息的分布检测规则。

值得指出的是,当前对于WSN中的分布式检测,通常也假设传感器与融合中心之间的通信信道是理想的<sup>[53]</sup>,而对于非理想信道情况,需要研究其对基于FDR控制的分布式检测性能和影响。建立检测ROI中一个单目标的FDR控制框架,并将该FDR框架扩展到检测ROI中多目标,这是WSN中分布式检测的一个值得关注的挑战性问题。此外,将FDR控制框架从每个传感器具有相同噪声扩展到具有不同噪声功率场景下的分布式检测也是值得关注的问题。

还有一个值得注意的问题是,对于WSN中密集部署传感器产生覆盖冗余的情况,选择一个传感器子集就能提供满足预期质量的观测信息。此时,分布式检测可以采用适宜的传感器管理,选择激活的传感器的一个子集或对提供信息的传感器资源进行可用分配,来满足与信息服务质量有关的应用需求。

本章主要研究并行分布式判定融合结构,其中各传感器将其基于自身观测的局部检测直接传输到融合中心。对于如图5.3所示的串联分布式判定检测结构,还涉及精确信号检测和有效能量传输路径等分布式数据处理,这也是当前出现的一个有成效的研究领域<sup>[83,84]</sup>。

## 参考文献

[1] A P Sage, J L Melsa. Estimation Theory with Application to Communications and Control. McGraw-

- Hill, 1971.
- [2] P K Varshney. Distributed Detection and Data Fusion. New York: Springer, 1997.
  - [3] H L Van Trees. Detection, Estimation and Modulation Theory. New York: Wiley, 1968, Vol. 1.
  - [4] H.V. Poor. An Introduction to Signal Detection and Estimation. New York: Springer-Verlag, 1988.
  - [5] C.W. Helstrom. Elements of Signal Detection and Estimation. Prentice-Hall, Englewood Cliffs. NJ, 1995.
  - [6] R Viswanathan, P K Varshney. Distributed detection with multiple sensors: Part I—Fundamentals. Proceedings of the IEEE, January, 1997, 85(1), 54–63.
  - [7] R S Blum, S A Kassam, H V Poor. Distributed detection with multiple sensors: Part II—Advanced topics. Proceedings of the IEEE, January, 1997, 85(1), 64–79.
  - [8] V Veeravalli, P K Varshney. Distributed inference in wireless sensor networks. Philosophical Transactions of the Royal Society, January, 2012, 370(1958), 100–117.
  - [9] J P Shaffer. Multiple hypothesis testing. Annual Review of Psychology, 1995, 46(1), 561–584.
  - [10] M Schwartz, W R Bennett, S Stein. Communication Systems and Techniques. New York: Wiley, 1995.
  - [11] B Eisenberg, B K Ghosh, P K Sen, et al. Multihypothesis problems, in Handbook of Sequential Analysis. New York, Marcel Dekker, 1991, Vol. 118, 229–244.
  - [12] X Zhu, Y Yuan, C Rorres, et al. Distributed M-ary hypothesis testing with binary local decisions. Information Fusion, 2004, 5(3), 157–167.
  - [13] Q Zhang, P K Varshney. Decentralized M-ary detection via hierarchical binary decision fusion. Information Fusion, 2001, 2(1), 3–16.
  - [14] C W Baum, V V Veeravalli. A sequential procedure for multihypothesis testing. IEEE Transactions on Information Theory, 1994, 40(6), 1994–2007.
  - [15] J Tsitsiklis, M Athans. On the complexity of decentralized decision making and detection problems. IEEE Transactions on Automatic Control, May, 1985, 30, 440–446.
  - [16] N S V Rao. Computational complexity issues in synthesis of simple distributed detection networks. IEEE Transactions on Systems, Man, Cybernetics, September/October 1991, 21, 1071–1081.
  - [17] J N Tsitsiklis, H.V. Poor, J B Thomas, et al. Decentralized detection, in Advances in Statistical Signal Processing. JAI Press, Greenwich, CT, 1993.
  - [18] J N Tsitsiklis. On threshold rules in decentralized detection. in Proceedings of the 25th IEEE Conference on Decision and Control, Athens, Greece, 1986, 232–236.
  - [19] P Willet, D Warren. Decentralized detection: When are identical sensors identical. in Proceedings Conference on Information Science and Systems, Princeton, NJ, 1991, 287–292.
  - [20] D L Hall, C-Y Chong, J Llinas, et al. Distributed Data Fusion for Network-centric Operations. CEC press Boca Raton, Chapter 4.
  - [21] 康耀红. 数据融合理论与应用. 西安: 西安电子科技大学出版社, 1997.
  - [22] Z B Tang, K R Pattipati, D Kleinman. An algorithm for determining the detection thresholds in a distributed detection problem, IEEE Transactions on Systems, Man, and Cybernetics, January/February 1991, 21,

231–237.

- [23] A R Reibman. Performance and Fault-Tolerance of Distributed Detection Networks. PhD thesis, Duke University, Durham, NC, 1987.
- [24] S C A Thomopoulos, R Viswanathan, D K Bougoulas. Optimal distributed decision fusion, IEEE Transactions on Aerospace and Electronic Systems, September 1989, 25, 761–765.
- [25] Z Chair, P K Varshney. Optimal data fusion in multiple sensor detection systems. IEEE Transactions on Aerospace and Electronic Systems, January, 1986, 22, 98–101.
- [26] J B Thomas. Nonparametric detection, Proceedings of the IEEE, 1970, 58(5), 623–631.
- [27] S Kay. Can detectability be improved by adding noise? IEEE Signal Processing Letters, 7(1), 8–10, January 2000.
- [28] H Chen, P K Varshney, S M Kay, et al. Theory of the stochastic resonance effect in signal detection: Part I; fixed detectors. IEEE Transactions on Signal Processing, July, 2007, 55(7), 3172–3184.
- [29] H Chen, P K Varshney. Theory of the stochastic resonance effect in signal detection: Part II; variable detectors. IEEE Transactions on Signal Processing, October, 2008, 56(10), 5031–5041.
- [30] P F Swaszek. On the performance of serial networks in distributed detection. IEEE Transactions on Aerospace and Electronic Systems, January, 1993, 29(1), 254–260.
- [31] Z B Tang, K R Pattipati, D L Kleinman. Optimization of detection networks I Tandem structures. IEEE Transactions on Systems, Man and Cybernetics, September/October, 1991, 21(5), 1044–1059.
- [32] W P Tay, J N Tsitsiklis, M Z Win. On the subexponential decay of detection error probabilities in long tandems, IEEE Transactions on Information Theory, October, 2008, 54(10), 4767–4771.
- [33] Z B Tang, K R Pattipati, D L Kleinman. Optimization of detection networks II Tree structures, IEEE Transactions on Systems, Man and Cybernetics, January/February 1993, 23(1), 211–221.
- [34] W P Tay, J N Tsitsiklis, M Z Win. On the impact of node failures and unreliable communications in dense sensor networks, IEEE Transactions on Signal Processing, June, 2008, 56(6), 2535–2546.
- [35] W P Tay, J N Tsitsiklis, M Z Win. Bayesian detection in bounded height tree networks. IEEE Transactions on Signal Processing, October, 2009, 57(10), 4042–4051.
- [36] Q Zou, S Zheng, A H Sayed. Cooperative sensing via sequential detection. IEEE Transactions on Signal Processing. December, 2010, 58(12), 6266–6283.
- [37] Q Cheng, P K Varshney, K G Mehrotra, and et al. Bandwidth management in distributed sequential detection. IEEE Transactions on Information Theory, August, 2005, 51(8), 2954–2961.
- [38] H Chen, P K Varshney, J H Michels. Improving sequential detection performance via stochastic resonance. IEEE Signal Processing Letters, 2008, 15, 685–688.
- [39] V V Veeravalli. Decentralized quickest change detection. IEEE Transactions on Information Theory, 47(4), 1657–1665, May 2001.
- [40] R Niu, P K Varshney. Sampling schemes for sequential detection with dependent data, IEEE Transactions on Signal Processing, March, 2010, 58(3), 1469–1481.

- [41] J N Tsitsiklis. Decentralized detection with a large number of sensors. *Mathematics of Control, Signals, and Systems*, 1988, 1, 167–182.
- [42] P Chen, A Papamarcou. New asymptotic results in parallel distributed detection. *IEEE Transactions on Information Theory*, November, 1993, 39(6), 1847–1863.
- [43] J Chamberland, V V Veeravalli. Decentralized detection in sensor networks. *IEEE Transactions on Signal Processing*, February, 2003, 51, 407–416.
- [44] J F Chamberland, V V Veeravalli. Asymptotic results for decentralized detection in power constrained wireless sensor networks. *IEEE Journal on Selected Areas in Communications*, August, 2004, 22(6), 1007–1015.
- [45] R Niu, P K Varshney, Q Cheng. Distributed detection in a large wireless sensor network. *International Journal on Information Fusion*, December, 2006, 7(4), 380–394.
- [46] R Niu, P K Varshney. Distributed detection and fusion in a large wireless sensor network of random size. *EURASIP Journal on Wireless Communications and Networking*, September, 2005, 5(4), 462–472.
- [47] R Niu, P K Varshney. Performance analysis of distributed detection in a random sensor field. *IEEE Transactions on Signal Processing*, 56(1), 339–349, January 2008.
- [48] B Krishnamachari and S. Iyengar, Distributed Bayesian algorithms for fault-tolerant event region detection in wireless sensor networks. *IEEE Transactions on Computers*, March, 2004, 53(3), 241–250.
- [49] R Niu P K Varshney, Performance analysis of distributed detection in a random sensor field, *IEEE Transactions on Signal Processing*, January, 2008, 56(1), 339–349.
- [50] F Gini, F Lombardini, L Verrazzani. Decentralized CFAR detection with binary integration in weibull clutter. *IEEE Transactions on Aerospace and Electronic Systems*, April, 1997, 33(2), 396–407.
- [51] F Gini, F Lombardini, L Verrazzani. Decentralised detection strategies under communication constraints. *IEE Proceedings—Radar, Sonar and Navigation*, 145(4), August, 1998, 199–208.
- [52] F Gini, F Lombardini, P K Varshney. On distributed signal detection with multiple local free parameters. *IEEE Transactions on Aerospace and Electronic Systems*, October, 1999, 35(4), 1457–1466.
- [53] P Ray, P K Varshney. False discovery rate based sensor decision rules for the network-wide distributed detection problem. *IEEE Transactions on Aerospace and Electronic Systems*, July, 2011, 47(3), 1785–1799.
- [54] E L Lehman, J P Romano. *Testing Statistical Hypotheses*, Springer, New York, 3rd edn, 2008.
- [55] Y Benjamini, Y Hochberg. Controlling the false discovery rate: A practical and powerful approach to multiple testing, *Journal of the Royal Statistical Society, Series B*, 1995, 57(1), 289–300.
- [56] Y Benjamini, D Yekutieli. The control of the false discovery rate in multiple testing under dependency. *Annals of Statistics*, 2001, 29, 1165–1188.
- [57] G S Lauer, N R Sandell Jr, Distributed detection with waveform observations: Correlated observation processes. in *Proceedings of the 1982 American Controls Conference*, Arlington, VA, 1982, Vol. 2, 812–819.
- [58] P Chen, A Papamarcou. Likelihood ratio partitions for distributed signal detection in correlated Gaussian noise. in *Proceedings of IEEE International Symposium on Information Theory*, Whistler, Canada,

September 1995, 118.

- [59] V Aalo, R Viswanathan. On distributed detection with correlated sensors: Two examples. *IEEE Transactions on Aerospace and Electronic Systems*, May, 1989, 25, 414–421.
- [60] V Aalo, R. Viswanathan. Asymptotic performance of a distributed detection system in correlated Gaussian noise. *IEEE Transactions on Signal Processing*, January, 1992, 40, 211–213.
- [61] R Blum, P Willett, P Swaszek. Distributed detection of known signals in nonGaussian noise which is dependent from sensor to sensor. in *Proceedings of Conference of the Information Sciences and Systems*, Baltimore, MD, March 1997, 825–830.
- [62] X Lin, R Blum. Numerical solutions for optimal distributed detection of known signals in dependent t-distributed noise: The two-sensor problem, in *Proceedings of the Asilomar Conference on Signals, Systems, and Computers*, Pacific Grove, CA, November, 1998, 613–617.
- [63] Z Tang, K Pattipati, D Kleinman. A distributed M-ary hypothesis testing problem with correlated observations. *IEEE Transactions on Automatic Control*, July, 1992, 37, 1042–1046.
- [64] P K Willett, P F Swaszek, R S Blum. The good, bad, and ugly: Distributed detection of a known signal in dependent Gaussian noise. *IEEE Transactions on Signal Processing*, December, 2000, 48, 3266–3279.
- [65] H Chen, P K Varshney, B Chen. A novel framework for distributed detection with dependent observations. *IEEE Transactions on Signal Processing*, March, 2012, 60(3), 1409–1419.
- [66] E Drakopoulos, C C Lee. Optimum multisensor fusion of correlated local decisions. *IEEE Transactions on Aerospace and Electronic Systems*, July, 1991, 27(4), 593–606.
- [67] M Kam, Q Zhu, W S Gray. Optimal data fusion of correlated local decisions in multiple sensor detection systems. *IEEE Transactions on Aerospace and Electronic Systems*, July, 1992, 28(3), 916–920.
- [68] D D Mari, S Kotz. *Correlation and Dependence*. Imperial College Press, London, U K, 2001.
- [69] R B Nelsen. *An Introduction to Copulas*. New York: Springer-Verlag, 1999.
- [70] A Sundaresan, P K Varshney, N S V Rao. Copula-based fusion of correlated decisions. *IEEE Transactions on Aerospace and Electronic Systems*, 2011, 47(1), 454–471.
- [71] S G Iyengar, P K Varshney, T Damarla. A parametric copula-based framework for hypothesis testing using heterogeneous data, *IEEE Transactions on Signal Processing*, May, 2011, 59(5), 2308–2319.
- [72] A Sundaresan. *Detection and source location estimation of random signal sources using sensor networks*, PhD thesis, Syracuse University, Syracuse, New York, 2010.
- [73] B Chen, R Jiang, T Kasetkasem, et al. Channel aware decision fusion for wireless sensor networks, *IEEE Transactions on Signal Processing*, December, 2004, 52, 3454–3458.
- [74] I Bahceci, G Al-Regib, Y Altunbasak. Parallel distributed detection for wireless sensor networks: Performance analysis and design. in *IEEE Global Telecommunications Conference*, 2005, Vol. 4, 5.
- [75] R Niu, B Chen, P K Varshney. Fusion of decisions transmitted over Rayleigh fading channels in wireless sensor networks, *IEEE Transactions on Signal Processing*, March, 2006, 54(3), 1018–1027.
- [76] R Jiang, B Chen. Fusion of censored decisions in wireless sensor networks. *IEEE Transactions on Wireless*



- Communications, November, 2005, 4(6), 2668–2673.
- [77] Y Lin, B Chen, P K Varshney, Decision fusion rules in multi-hop wireless sensor networks. IEEE Transactions on AES, April, 2005, 51, 475–488.
- [78] I Bahceci, G Al-Regib, Y Altunbasak. Serial distributed detection for wireless sensor networks, in International Symposium on Information Theory, ISIT, Adelaide, Australia, 2005, 830-834.
- [79] B Chen, P K Willett. On the optimality of likelihood ratio test for local sensor decision rules in the presence of non-ideal channels. IEEE Transactions on Information Theory, 2005, 51(2), 693-699.
- [80] B Liu, B Chen. Channel optimized quantizers for decentralized detection in wireless sensor networks. IEEE Transactions on Information Theory, July, 2006, 52, 3349-3358.
- [81] B Liu, B Chen. Decentralized detection in wireless sensor networks with channel fading statistics, EURASIP Journal on Wireless Communications and Networking, January, 2007.
- [82] Y Lin, B Chen, B Suter. Robust binary quantizers for distributed detection. IEEE Transactions on Wireless Communications, June, 2007, 6(6), 2172-2181.
- [83] Y Yang, R S Blum, B M Sadler. Energy-efficient routing for signal detection in wireless sensor networks. IEEE Transactions on Signal Processing, 2009, 57(6), 2050-2063.
- [84] Y Sung, S Misra, L Tong, et al. Cooperative routing for distributed detection in large sensor networks. IEEE Journal on Selected Areas in Communications, 2007, 25(2), 471-483.
- [85] 周概容. 概率论与数理统计. 北京：高等教育出版社, 1983.

# 第6章 航迹融合与航迹关联——分布式多目标跟踪要点

## 6.1 引言

在分布式战场感知系统中,对于重要的动态目标(空中、海上目标或地面移动目标),通常利用多个观测站点,对其进行定位、识别与跟踪,同时将目标航迹上传至航迹融合站点( $T^2F$ ),生成全局航迹和识别结果,为作战决策和行动提供支持信息。前面几章所描述的有别于集中式融合的分布式融合体系结构及一系列新的挑战性问题 and 求解方法已经在分布式目标跟踪中得到了广泛应用。分布式多目标跟踪问题可以视为传统集中式融合的目标状态估计(滤波)问题从单目标向多目标的扩展<sup>[62, 39, 40, 1]</sup>,其中目标状态、目标身份(属性)和目标数量都可能是未知的,均需要估计。由于目标跟踪所依据的观测数据通常来源于多目标和非关注对象(杂波、虚警等)<sup>[9, 4, 5, 10, 6, 7]</sup>,因此,多目标跟踪是带有数据关联的多目标状态估计问题,或者说,数据关联是实现多目标状态融合估计的前提。

为小型系统实现信息化所设计的信息融合系统,通常采用一组信息源如传感器,通过对其观测数据进行融合来获得最优或近似最优的目标状态估计。而对于大规模系统来说,这种将它们提供的观测数据集中到一起进行融合的集中式信息处理方式并不适宜,这是由于一个集中融合站点失效会导致整个系统功能丧失,并且传输所有传感器数据到一个集中融合节点需要较大的通信带宽,融合站点计算负载过重也是系统的瓶颈问题之一。因此,大型系统信息处理设计的优选方案必然是分布式结构。分布式融合结构能够均匀分配通信带宽和各节点的计算负荷,单一节点失效不会导致系统失效,从而提高系统的健壮性和可用性。此外,如第3章所述,分布式系统还能够解决信息重复使用产生的相关性,以避免融合误差协方差增长,并且能够在一定程度上解决网络带宽、时间延误、过程噪声、信息相关以及单一节点局部功能与全局功能优化的整体协调与平衡等问题,使系统功能满足网络中心战多节点整体作战活动的需求。

分布式目标跟踪系统是随着目标状态的动态变化和测量信息的到来逐周期分布式进行目标定位、识别和跟踪(航迹生成与延续)的过程。这里描述一下分布式目标跟踪中的两个关键的概念和内涵,以期在后续研究、讨论和应用中达成一致的认识和理解。

第一个关键概念是航迹相关。集中式跟踪系统中的航迹相关在概念上指确定表示同一目标的局部航迹集合的过程,这实际上是判定(航迹)级别上的关联功能,因此成为航迹融合的前提条件。而分布式跟踪中的航迹相关与集中式跟踪中的概念完全不同,分布式跟踪中的航迹相关是指若两条或两条以上航迹在生成过程中共同使用了某个或某些信息源提供的信

息（称为共用信息，如某传感器测量数据），则称这些航迹是相关的，或称生成这些航迹的输入数据是非统计独立的。在这个定义下，两条相关航迹的融合必然重复使用了某些共用信息，因此，分布式跟踪系统的局部航迹相关与全局航迹融合中的信息重复使用的概念紧密联系在一起。图 6.1 给出了相关航迹融合结构及其跟踪源关注范围（ROI）相互覆盖示意图。

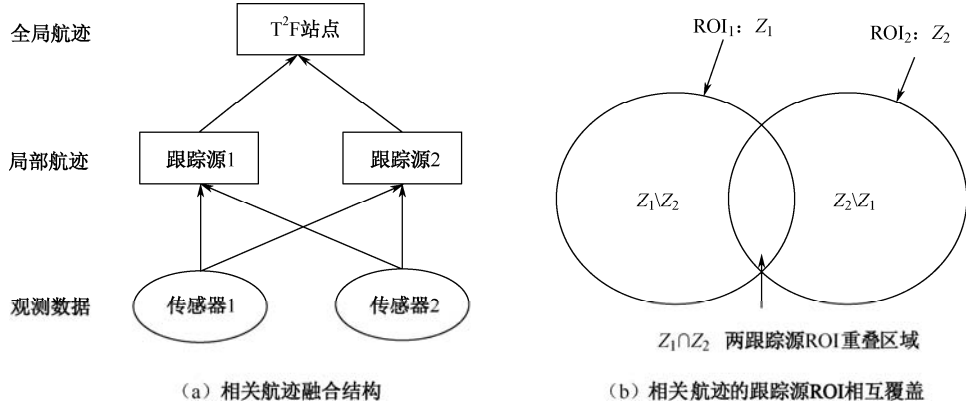


图 6.1 相关航迹融合结构及其跟踪源 ROI 相互覆盖示意图

图 6.1 (a) 所示结构描述了两个传感器探测信息分别为两个跟踪源共用，所生成的两条局部航迹是相关的。这两个跟踪源将其生成的局部航迹传递给某一航迹——航迹融合（ $T^2F$ ）站点，生成的全局航迹中显然两次使用了传感器 1 和传感器 2 的观测数据。这就说明了分布式系统中相关航迹的融合必将导致传感器观测数据的重复使用。

图 6.1 (b) 给出了两跟踪源关注范围（ROI）重叠的概念，它是分布式融合航迹相关的图形表示。其中  $Z_i$  表示跟踪源  $i$  所关注的目标范围（ $ROI_i$ ，或称监视责任区， $i=1,2$ ），无论采用什么探测手段（传感器），只要观测到  $Z_i$  范围内的目标（或杂波/虚警），必然要传递给跟踪源  $i$ 。这样一来，如果某传感器观测到两跟踪源关注范围重叠区域  $Z_1 \cap Z_2$  中的目标，自然要同时传递给这两个跟踪源，从而出现图 6.1 (a) 所示的两跟踪源生成相关航迹的情况。文献[67]7.3.2 节给出了消除两相关航迹共用信息的贝叶斯原理，即针对图 6.1 (b) 所示的两跟踪源相关航迹的全局融合估计中重复采用同一探测信息问题，通过下述公式予以去除：

$$P(x|Z_1 \cup Z_2) = C^{-1} P(x|Z_1) \cdot P(x|Z_2) / P(x|Z_1 \cap Z_2) \quad (6.1)$$

式中， $P(x|Z_1)$  和  $P(x|Z_2)$  分别表示两跟踪源对目标状态的局部估计概率密度，两跟踪源共用探测信息概率密度为  $P(x|Z_1 \cap Z_2)$ ，当它位于式 (6.1) 分母中时则表示在对两局部航迹的全局融合中扣除该共用信息一次。值得指出的是，文献[4]及许多文献采用两传感器探测覆盖概念来解释探测信息重复使用及扣除重复信息的贝叶斯原理似乎不妥，因其易将单一信息源探测信息的重复使用产生的负面影响与多传感器独立探测信息融合的正效应混淆在一起。

第二个关键概念是数据关联。数据关联在概念上定义为获取来自同一目标（或杂波）的数据集合的过程。在分布式跟踪系统中，数据关联通常分为局部数据关联和全局数据关联，具体描述如下：①局部数据关联，指将传感器测量数据融入目标局部航迹（或杂波）的分配过程，目的是实现已有目标局部航迹的延续或杂波滤除，至于更前端的传感器测量点迹聚集

生成航迹以及目标航迹的终结识别则不是分布式目标跟踪讨论的重点。②全局数据关联,指将各跟踪源的局部航迹融入全局航迹之中的分配过程,目的是实现全局航迹的起始和延续或虚假局部航迹的滤除。上述这两类数据关联概念是将关联与融合作为一个整体定义的。实际上,关联与融合在内涵上并不相同,关联是产生来源于同一目标(航迹)的测量集合或局部航迹集合,为融合起始、延续局部(或全局)目标航迹提供输入信息集合,因此,关联成为融合的前提条件。与集中式融合系统一样,分布式跟踪系统中的关联也存在测量—航迹关联(MTA)和航迹—航迹关联(TTA)中一对多或多对一无法进行唯一分配的模糊现象,特别在目标密集、目标交叉或机动及强杂波/干扰环境中,这两类模糊更加突出,由传感器测量误差和航迹估计误差所产生的漏关联和虚关联导致的虚假航迹和冗余航迹,是至今难以解决的问题。

分布式目标跟踪与多目标集中式跟踪的研究几乎同时开始,在一篇先导性研究文献[58]和两篇创新论文[2,3]中提出了分布式跟踪的两个要点,即航迹关联与航迹融合。如第4章所述,自20世纪90年代以来,分布式航迹融合均以公式形式表述,并在分布式估计框架下使用通用传感器和信息网络进行航迹关联与航迹融合模型的选择和求解<sup>[19,21,46]</sup>。自此以后,陆续出现了大量航迹融合的论文<sup>[34,29,8,47,26,48,63,44]</sup>。

迄今为止,许多分布式跟踪系统已被开发和运行,其中既有军事系统又有民用系统<sup>[26,46,23,49,28,45]</sup>,所产生的系统工程应用成果在学界称为融合结构研究成果,这些成果通过实际应用检验了分布式系统所实现的多种功能算法能够达到的性能。近年来,分布式目标跟踪课题正在转向健壮性<sup>[29]</sup>和大规模分布式传感器网络等研究领域<sup>[36]</sup>。

本章并不描述分布式跟踪的整个领域,只展现其两个要点,即航迹关联与航迹融合。目前已提出的各种方法主要包括一次航迹融合方法和反复航迹融合方法以及具体的融合准则,并尽可能通过仿真案例验证并定量比较各融合准则的性能。本章还描述了航迹关联度量指标,并对各度量指标进行了仿真验证和比较。为了突出对航迹关联与航迹融合概念的理解和性能比较,在仿真验证中,将范围界定为简单的具有典型代表性的 Ornstein—Uhlenbeck 抽象数学模型,但也尽可能包含更多的实际因素。在分布式跟踪中对反复进行信息交换产生的航迹融合效果进行融合准则性能比较时,考虑了同类传感器与异类传感器的融合结构,并与集中式跟踪性能进行了比较,对动态特性则考虑了归一化噪声、初始位置不确定性等变化所引起的目标融合估计位置、速度等状态参数的变化。在航迹融合与航迹关联方法、准则、指标及性能的验证中,我们将系统结构选择为具有最小复杂性的两个传感器或两个局部融合站点系统。采用该结构使我们能够对航迹融合和关联这两个要点进行分离,从而对许多准则和指标进行清晰的比较,并能够讨论分布式跟踪的关键设计要素,如带有和不带有反馈的融合结构以及已过去的信息交换存储深度等因素对跟踪效果的影响等。

## 6.2 航迹融合的概念与模型

由于信息融合中关联问题的研究重点在传感器测量即信号和数据(点迹)级,航迹级关

联并不是信息融合的重点，目前该领域的研究内容并不多。因此，尽管航迹关联是航迹融合的前提条件，本章仍以航迹融合为主要研究对象，即阐述迄今为止基于来自同一目标的局部航迹集合实现全局航迹融合的方法、准则和性能的仿真验证比较。而仅用一节的篇幅描述航迹关联问题。

为准确、深入描述和理解航迹融合的概念，我们仅考虑来自两个跟踪源（传感器）的局部航迹的全局融合问题，并以一次融合方法和准则进行展开描述。

### 6.2.1 目标动态与观测模型

假设有两个跟踪源的传感器观测同一目标：

$$\mathbf{z}_{ik} = \mathbf{H}_{ik} \mathbf{x}(t_{ik}) + \boldsymbol{\eta}_{ik} \quad i=1,2 \quad (6.2)$$

式中， $t_{ik}$  是传感器  $i$  的观测时间， $k=1, \dots, N_i$ ， $t_{i1} < \dots < t_{iN_i}$ ，每个测量误差  $\boldsymbol{\eta}_{ik}$  是相互独立、均值为零的高斯随机向量，其协方差矩阵为  $\mathbf{R}_{ik} = E(\boldsymbol{\eta}_{ik}, \boldsymbol{\eta}_{ik}^T)$ ， $\mathbf{H}_{ik}$  是与测量和目标状态维数适应的观测矩阵。

式（6.2）中的目标状态  $\mathbf{x}(t)$  是下述动态方程定义的目标状态：

$$\frac{d\mathbf{x}(t)}{dt} = \mathbf{A}(t)\mathbf{x}(t) + \mathbf{B}(t)\dot{\mathbf{w}}(t) \quad (6.3)$$

式中， $\mathbf{x}(t)(t \in [t_0, \infty), t_0 = \min\{t_{11}, t_{12}\})$  是欧氏目标空间中的状态，因此式（6.3）表示的是一个随机微分方程  $d\mathbf{x}(t) = \mathbf{A}(t)\mathbf{x}(t)dt + \mathbf{B}(t)d\mathbf{w}(t)$ ，它是带有单位噪声强度的维纳过程  $\mathbf{w}(t)$ ， $t_0 \leq t < \infty$ ，并假设  $\mathbf{x}(t_0)$ 、 $\mathbf{w}(t)$ 、 $\{\boldsymbol{\eta}_{ik}\}_{k=1}^{N_i}(i=1,2)$  相互独立。目标初始状态  $\mathbf{x}(t_0)$  是高斯随机向量，均值为  $\bar{\mathbf{x}}_0$ ，协方差矩阵为  $\bar{\mathbf{v}}_0$ ，即  $P[\mathbf{x}(t_0)] = g[\mathbf{x}(t_0) - \bar{\mathbf{x}}_0; \bar{\mathbf{v}}_0]$ ，这里  $g$  表示零均值高斯密度函数，即

$$g(\boldsymbol{\xi}, \mathbf{v}) = \det(2\pi\mathbf{v})^{-\frac{1}{2}} \exp[-\frac{1}{2}\boldsymbol{\xi}^T \mathbf{v}^{-1} \boldsymbol{\xi}] \quad (6.4)$$

### 6.2.2 一次航迹融合的概念

两跟踪站点（传感器）的  $T^2F$  一次融合在概念上是指仅对一次提供的两条局部航迹信息（含先验信息）进行融合，以实现目标定位和航迹延续，如图 6.2（a）所示。其中局部航迹信息包括目标航迹的状态估计  $\hat{\mathbf{x}}_i$  及其估计误差协方差矩阵  $\mathbf{V}_i (i=1,2)$ 。先验状态信息  $\bar{\mathbf{x}}$  及其协方差  $\bar{\mathbf{V}}$  通常来源于上一次全局融合估计，也可来源于两个局部估计的先验信息。

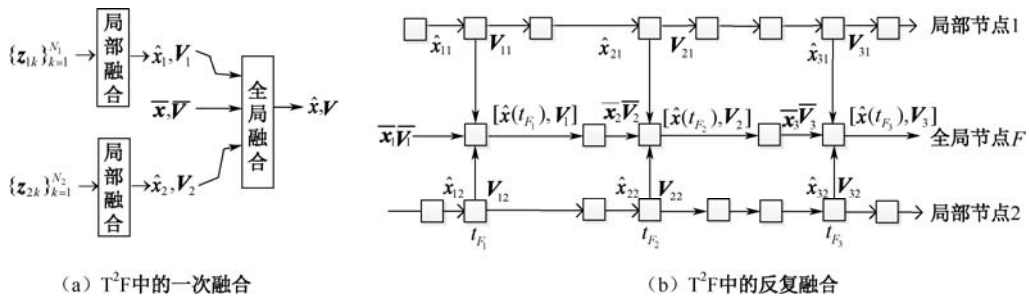


图 6.2 两跟踪站点的  $T^2F$  一次融合与反复融合

在一次航迹融合中,两局部估计是局部站点基于一段时间内的传感器测量集合生成的同一融合时刻 $t_F$ 的目标状态估计及其误差协方差:

$$\begin{aligned}\hat{\mathbf{x}}_i &= E[\mathbf{x}(t_F) | (\mathbf{z}_{ik})_{k=1}^{N_i}] \\ \mathbf{V}_i &= E[\hat{\mathbf{x}}_i - \mathbf{x}(t_F)][\hat{\mathbf{x}}_i - \mathbf{x}(t_F)]^T\end{aligned}\quad i=1,2 \quad (6.5)$$

融合时刻 $t_F \geq \max\{t_{1N_1}, t_{2N_2}\}$ 也是全局融合时刻,如果先验信息 $\bar{\mathbf{x}}, \bar{\mathbf{V}}$ 在 $t_F$ 之前生成,还要进行 $t_F$ 时刻预测,然后才能参与航迹融合。这里假设参与融合的局部状态估计误差协方差矩阵是严格正定的, $P[\mathbf{x}(t_F) | (\mathbf{z}_k)_{k=1}^{N_i}] = g[\mathbf{x}(t_F) - \mathbf{x}_i; \bar{\mathbf{V}}_i] (i=1,2)$ 服从高斯分布。当然,先验状态信息的误差协方差矩阵 $\bar{\mathbf{V}}$ 也假设是严格正定的。这样一来,一次航迹融合问题就定义为:基于同一时刻对同一目标两个局部估计及其误差协方差,确定该目标该时刻状态的一个全局“最优”估计。采用的融合准则不同,所获得的全局优化估计精度也不相同。

两个局部估计误差的联合概率密度函数为

$$P\{[\hat{\mathbf{x}}_1 - \mathbf{x}(t_F)], [\hat{\mathbf{x}}_2 - \mathbf{x}(t_F)]\} = g\left(\begin{bmatrix} \hat{\mathbf{x}}_1 - \mathbf{x}(t_F) \\ \hat{\mathbf{x}}_2 - \mathbf{x}(t_F) \end{bmatrix}; \begin{bmatrix} \mathbf{V}_1 & \mathbf{V}_{12} \\ \mathbf{V}_{21} & \mathbf{V}_2 \end{bmatrix}\right) \quad (6.6)$$

式中,交叉协方差 $\mathbf{V}_{12} = E\{[\hat{\mathbf{x}}_1 - \mathbf{x}(t_F)][\hat{\mathbf{x}}_2 - \mathbf{x}(t_F)]^T\}$  ( $\mathbf{V}_{21} = \mathbf{V}_{12}^T$ )表示目标动态方程(6.3)的初始条件 $\mathbf{x}(t_0) = \mathbf{x}_0$ 和过程噪声 $\mathbf{w}(t)|_{t \in [t_0, \infty)}$ 为两个局部跟踪站点共用所产生的相关效应。

在已有的融合准则和方法中,两局部估计误差 $\tilde{\mathbf{x}}_i = \hat{\mathbf{x}}_i - \mathbf{x}(t_F) (i=1,2)$ 通常具有下述性质:

① 局部估计误差 $\tilde{\mathbf{x}}_i$ 与状态估计 $\hat{\mathbf{x}}_i$ 相互正交(独立),即 $\tilde{\mathbf{x}}_i$ 与 $\hat{\mathbf{x}}_i$ 距离最近。该事实首先是基于传统高斯估计确定的<sup>[1]</sup>。

② 两个局部估计误差向量 $\tilde{\mathbf{x}}_1$ 与 $\tilde{\mathbf{x}}_2$ 是相关的,这是由两个估计器共用动态方程的初始条件和过程噪声引起的。

③ 每个局部估计误差 $\tilde{\mathbf{x}}_i$ 对于 $t_F$ 时刻的全局状态 $\mathbf{x}(t_F)$ 不一定是独立的,这依赖于局部状态估计 $\hat{\mathbf{x}}_i$ 与初始条件是否相关,通常是未知的。

这里的②和③是分布式航迹融合的显著特征,注意到这一点能够使我们避免将两个局部估计(像集中式融合那样)当作对目标状态 $\mathbf{x}(t_F)$ 的两个相互独立的传感器测量进行处理。

对于非线性目标动态和非线性观测模型的目标航迹融合问题,可以将式(6.6)视为对一个非高斯融合估计误差概率密度的高斯近似。

### 6.2.3 反复航迹融合的概念

对同一目标的两条跟踪航迹的反复融合问题主要是针对重要目标的分布式(多站点)连续跟踪的需求,其中各局部站点与全局融合站点随着时间的推移,反复进行通信及航迹信息的交换与融合,以提升目标航迹的精度和连续性。反复航迹融合通常采用如图6.2(b)所示的两层次结构,假设两局部站点在 $t_{F_1}, t_{F_2}, t_{F_3}$ 向全局站点同步传送局部航迹信息 $[(\hat{\mathbf{x}}_{11}, \mathbf{V}_{11}), (\hat{\mathbf{x}}_{12}, \mathbf{V}_{12})], [(\hat{\mathbf{x}}_{21}, \mathbf{V}_{21}), (\hat{\mathbf{x}}_{22}, \mathbf{V}_{22})]$ 和 $[(\hat{\mathbf{x}}_{31}, \mathbf{V}_{31}), (\hat{\mathbf{x}}_{32}, \mathbf{V}_{32})]$ 以在全局站点同步实现融合。在对目标航迹连续跟踪的反复融合问题中,需说明下述几个问题:

反复融合并不是多个不同时刻一次航迹融合简单叠加，而是上游节点对下游节点提供信息支撑，包括上游局部站点节点和全局站点节点对下游局部站点节点和全局站点节点的支撑关系，以实现目标（局部和全局）航迹的延续。对某一时刻的融合来说，全局上游节点以先验信息的形式对下游节点融合提供支撑，如图 6.2 (b) 中的  $(\bar{\mathbf{x}}_1, \bar{\mathbf{V}}_1)$ 、 $(\bar{\mathbf{x}}_2, \bar{\mathbf{V}}_2)$  和  $(\bar{\mathbf{x}}_3, \bar{\mathbf{V}}_3)$ 。

图 6.2 (b) 仅给出了两层无反馈融合结构，实际上，在反复航迹融合过程中，既存在通常的局部站点向全局站点传送局部航迹，也可能基于用户需求出现全局站点向局部站点传送全局航迹以提升目标的局部跟踪精度；甚至可以不设置全局站点，而是单一层次的两局部站点相互交换局部航迹，各自实现基于两站点信息的自主跟踪状态。

在反复航迹融合过程中，无论是有反馈和无反馈的层次跟踪结构，还是单一层次的自主跟踪结构，都出现上游节点的融合航迹信息为多个下游节点共用而导致的航迹相关（不独立）问题。航迹相关可能在局部融合节点上出现，也可能在全局融合节点上出现。解除航迹相关才能提高融合航迹精度，通常可在应用容许范围内改变网络连接结构、采用解除航迹相关的融合算法（如贝叶斯估计算法、小航迹解相关算法）或采用某些启发性、近似算法消除或降低航迹相关性。

为使反复航迹融合达到优化，需要在融合结构（涉及信息重用）、网络带宽（涉及传输信息量和时间延误）、信息资源分配（涉及融合性能和带宽占用）、融合算法（涉及去除信息重用、优化航迹精度）、过程噪声（动态噪声和融合误差协方差）等因素之间寻求平衡点，这是不同于集中式融合的重要研究内容。

面向目标跟踪的反复航迹融合需要考虑航迹连续性、精度、实时性以及识别结果的符合性等性能指标，这涉及目标航迹所含有的多时刻目标状态的动态优化问题。因此需要随时间推移，基于各因素的动态变化不断寻求新的航迹优化平衡点。寻求航迹优化的实时变化特征正成为当前分布式目标跟踪研究的前沿问题之一。

## 6.3 一次航迹融合准则

### 6.3.1 一次航迹融合状态估计及其协方差

在本节的一次航迹融合中，为简单起见，省去时间标记，令  $\mathbf{x}_F = \mathbf{x}(t_F)$ ， $\bar{\mathbf{x}} = E[\mathbf{x}(t_F)]$ ，并记  $\mathbf{V} = E[(\mathbf{x} - \bar{\mathbf{x}})(\mathbf{x} - \bar{\mathbf{x}})^T]$ 。一次融合的输入信息为两局部融合航迹  $(\hat{\mathbf{x}}_1, \mathbf{V}_1)$ 、 $(\hat{\mathbf{x}}_2, \mathbf{V}_2)$  以及航迹的先验信息  $(\bar{\mathbf{x}}, \bar{\mathbf{V}})$ 。采用加权线性组合形式的全局融合状态估计和估计误差协方差矩阵为

$$\hat{\mathbf{x}}_F = \mathbf{w}_0 \bar{\mathbf{x}} + \mathbf{w}_1 \hat{\mathbf{x}}_1 + \mathbf{w}_2 \hat{\mathbf{x}}_2 \quad (6.7)$$

$$\mathbf{V}_F = [\mathbf{w}_0 \quad \mathbf{w}_1 \quad \mathbf{w}_2] \begin{bmatrix} \bar{\mathbf{V}} & \mathbf{V}_{01} & \mathbf{V}_{02} \\ \mathbf{V}_{01}^T & \mathbf{V}_1 & \mathbf{V}_{12} \\ \mathbf{V}_{02}^T & \mathbf{V}_{12}^T & \mathbf{V}_2 \end{bmatrix} \begin{bmatrix} \mathbf{w}_0^T \\ \mathbf{w}_1^T \\ \mathbf{w}_2^T \end{bmatrix} \quad (6.8)$$

式 (6.7) 中， $\mathbf{w}_0 + \mathbf{w}_1 + \mathbf{w}_2 = \mathbf{I}$ （无偏性），并且各权系数矩阵  $\mathbf{w}_0$ 、 $\mathbf{w}_1$ 、 $\mathbf{w}_2$  是常量且与传

传感器测量集合  $\{\mathbf{z}_{ik}\}_{k=1}^{N_i}$  ( $i=1,2$ ) 相互独立, 可有意选择或采用线性高斯假设获得。式 (6.8) 中, 协方差矩阵分量  $\mathbf{V}_i$  由输入信息提供, 而融合时刻  $t_F$  的先验状态方差  $\bar{\mathbf{V}}$  由上一时刻  $t_0$  的方差  $\bar{\mathbf{V}}_0$  经状态转移外推到  $t_F$  时刻得到。我们注意目标动态方程 (6.3) 的离散形式可写为

$$\mathbf{x}_{k+1} = \Phi(t_{k+1}, t_k) \mathbf{x}_k + \mathbf{w}_k \quad (6.9)$$

式中,  $\Phi(t, \tau)$  是由矩阵微分方程  $\frac{\partial}{\partial t} \mathbf{M}(t, \tau) = \mathbf{A}(t) \mathbf{M}(t, \tau)$  定义的基于动态微分方程线性系数矩阵  $\mathbf{A}(t)$  确定的基本解矩阵,  $\Phi(\tau, \tau) = \mathbf{I}$ 。于是  $t_F$  时刻的先验状态方差为

$$\bar{\mathbf{V}} = \Phi(t_F, t_0) \bar{\mathbf{V}}_0 \Phi(t_F, t_0)^T + \mathbf{Q}(t_F, t_0) \quad (6.10)$$

其中

$$\mathbf{Q}(t_F, t_0) = \int_{t_0}^{t_F} \Phi(t_F, \tau) \mathbf{B}(\tau) \mathbf{B}(\tau)^T \Phi(t_F, \tau)^T d\tau$$

在同步测量情况下, 式 (6.8) 中的交叉协方差矩阵  $\mathbf{V}_{ij}$  ( $i \neq j$ ;  $i, j = 0, 1, 2$ ) 的递推计算比较容易实现<sup>[2]</sup>。这里介绍一下扩展到非同步测量情况的交叉协方差矩阵的递推计算方法<sup>[50]</sup>。

设一个航迹融合周期内两局部站点测量时刻的并集为:  $T = \{t_{1k}\}_{k=1}^{N_1} \cup \{t_{2k}\}_{k=1}^{N_2}$ , 再设  $\{T_k\}_{k=1}^N$  是该并集  $T$  内各测量时刻的单一枚举有序集合:  $T_1 < T_2 < \dots < T_N$ 。不难得到:

$$T_k \in \begin{cases} I_k \{1\} : T_k = t_{1k'} & k \text{ 对应传感器1测量 } \{z_{1k'}\}_{k'=1}^{N_1} \text{ 中的某些 } k' \\ I_k \{2\} : T_k = t_{2k'} & k \text{ 对应传感器2测量 } \{z_{2k'}\}_{k'=1}^{N_2} \text{ 中的某些 } k' \\ I_k \{1, 2\} : T_k = t_{1k'} = t_{2k'} & k \text{ 同时对应 } \{z_{1k'}\}_{k'=1}^{N_1} \text{ 中和 } \{z_{2k'}\}_{k'=1}^{N_2} \text{ 中的某些 } k' \end{cases} \quad (6.11)$$

示例如图 6.3 所示。




图 6.3  $\Delta T = [t_{F(k-1)}, t_{F(k)}]$  中两传感器测量时刻及统一排序示例

从图 6.3 可以看出, 在该融合周期  $\Delta T$  中,

$I_k \{1\} : T_1 = t_{11}, T_3 = t_{12}, T_5 = t_{14}, T_7 = t_{15}, T_9 = t_{17}, T_{11} = t_{18}$ , 即  $k' = 1, 2, 4, 5, 7, 8$ ;

$I_k \{2\} : T_2 = t_{21}, T_6 = t_{23}, T_{10} = t_{25}$ , 即  $k' = 1, 3, 5$ ;

$I_k \{1, 2\} : T_4 = t_{13} = t_{22}, T_8 = t_{16} = t_{24}, T_{12} = t_{19} = t_{26}$ 。

再设  $\hat{\mathbf{V}}_{12(k-1)} = E[\tilde{\mathbf{x}}_{1(k-1)} \tilde{\mathbf{x}}_{2(k-1)}^T]$  是  $T_{k-1}$  时刻分别基于测量集合  $\{z_{1k'}(t_{1k'} \leq T_{k-1})\}$  和  $\{z_{2k'}(t_{2k'} \leq T_{k-1})\}$  的两局部估计误差  $\tilde{\mathbf{x}}_{1(k-1)}$  与  $\tilde{\mathbf{x}}_{2(k-1)}$  的交叉协方差矩阵,  $\bar{\mathbf{V}}_{12k}$  是  $\hat{\mathbf{V}}_{12(k-1)}$  外推到  $T_k$  时刻的交叉协方差矩阵预测。根据式 (6.10), 可知式 (6.12) 成立:



$$\bar{V}_{12k} = \Phi(T_k, T_{k-1}) \hat{V}_{12(k-1)} \Phi(T_k, T_{k-1})^T + Q(T_k, T_{k-1}) \quad (6.12)$$

于是可以得到  $T_k$  时刻交叉协方差矩阵  $\bar{V}_{12k}$  更新估计的递推计算公式为

$$\hat{V}_{12k} = \begin{cases} (I - K_{1k'} K_{1k'}) \bar{V}_{12k} & T_k \in I_k \{1\} \\ \bar{V}_{12k} (I - K_{2k''} K_{2k''}) & T_k \in I_k \{2\} \\ (I - K_{1k'} K_{1k'}) \bar{V}_{12k} (I - K_{2k''} K_{2k''})^T & T_k \in I_k \{1, 2\} \end{cases} \quad (6.13)$$

式中,  $K_{1k'}$  和  $K_{2k''}$  分别是两个局部跟踪站点融合其测量  $z_{1k'}$  和  $z_{2k''}$  所采用的卡尔曼递推滤波中的增益矩阵。将式 (6.12) 和式 (6.13) 与一个适宜的初始条件  $\hat{V}_{120} = \hat{V}_{12}(t_0)$  加到一起,  $t_F$  时刻两局部误差  $\tilde{x}_1(t_F)$  与  $\tilde{x}_2(t_F)$  之间的交叉协方差矩阵  $V_{12}$  就能够在该递推终点得到。若递推终点不是全局融合时间  $t_F$  ( $t_F > \max\{t_{1N_1}, t_{2N_2}\}$ , 如图6.3所示), 还需增加一个外推或(插值)步骤 (6.12)。

式 (6.8) 中的  $t_k$  时刻两局部估计误差  $\tilde{x}_{i(k)} (i=1, 2)$  与  $t_k$  时刻外推的先验信息误差  $\tilde{x}_{0k} = \bar{x}_{0(k)} - x_k$  之间的交叉协方差  $V_{01(k)}$  和  $V_{02(k)}$ , 在  $\{z_{ik'} | t_{ik'} \leq T_k\}$  条件下也可以采用外推公式 (6.12) 和更新公式 (6.13) 递推计算得到, 其中 (为求取卡尔曼滤波增益矩阵)  $V_{i(k-1)} (i=1, 2)$  自然应由两局部卡尔曼滤波提供, 而外推的先验信息误差方差矩阵  $\bar{V}$  则可由式 (6.10) 计算获得。

需要指出的是, 当某些统计量, 特别是交叉协方差  $V_{12}$  或  $V_{0i} (i=1, 2)$  无法精确计算, 或某些共用信息或相关性无法确知只能是隐式给出时, 所采用的融合准则是启发性或尝试性的。此时, 所获得两局部估计的融合结果未必可用, 表现为所获得的估计误差协方差矩阵  $V_F$  可能与式 (6.8) 定义的实际估计误差协方差矩阵相差甚远。若获得的  $V_F$  与式 (6.8) 表示的协方差矩阵相符合, 则称  $V_F$  是真实 (即与定义一致) 的, 若  $V_F$  过大, 则称其过于不利; 若过小, 责称其过于有利。

### 6.3.2 融合准则

这里的融合准则在概念上包含所考虑的不确定性因素和采用的权系数优化指标。

#### 1. 交叉协方差融合准则

交叉协方差 (Cross Covariance, CC) 融合准则又称为Bar Shalom—Campo融合准则<sup>[3]</sup>, 是考虑两局部估计误差的交叉协方差并使两局部估计误差的联合概率密度  $p(\hat{x}_1 - x, \hat{x}_2 - x)$  达极大的融合准则<sup>[44]</sup>, 实现公式如下:

$$\begin{aligned} \hat{x}_F &= w_1 \hat{x}_1 + w_2 \hat{x}_2 \\ V_F &= (w_1 \quad w_2) \begin{pmatrix} V_1 & V_{12} \\ V_{12}^T & V_2 \end{pmatrix} \begin{pmatrix} w_1^T \\ w_2^T \end{pmatrix} \end{aligned} \quad (6.14)$$

其中

$$w_i = (V_j - V_{ji})(V_1 + V_2 - V_{12} - V_{12}^T)^{-1} \quad i=1, 2, \quad j=3-i \quad (6.15)$$

即

$$V_F = V_1 - (V_1 - V_{12})(V_1 + V_2 - V_{12} - V_{12}^T)^{-1}(V_1 - V_{12}^T) \quad (6.16)$$

由于  $\mathbf{w}_0 = \mathbf{0}$ ,  $\mathbf{w}_1 + \mathbf{w}_2 = \mathbf{I}$ , 故由两局部估计的无偏性可导致该融合估计  $\hat{\mathbf{x}}_F$  的无偏性。由上述定义可知, CC 融合准则下的最优航迹状态估计为<sup>[44]</sup>

$$\hat{\mathbf{x}}_F = \arg \max_{\mathbf{x}} p(\tilde{\mathbf{x}}_1, \tilde{\mathbf{x}}_2) = p(\hat{\mathbf{x}}_1 - \mathbf{x}, \hat{\mathbf{x}}_2 - \mathbf{x}) \quad (6.17)$$

我们知道, 该联合概率密度  $p(\hat{\mathbf{x}}_1, \hat{\mathbf{x}}_2)$  并不是严格贝叶斯意义下的似然函数, 即不是给出真实状态  $\mathbf{x}$  的情况下, 局部估计  $\hat{\mathbf{x}}_1$  和  $\hat{\mathbf{x}}_2$  的条件联合概率密度函数  $L(\hat{\mathbf{x}}_1, \hat{\mathbf{x}}_2 | \mathbf{x}) = p(\hat{\mathbf{x}}_1, \hat{\mathbf{x}}_2 | \mathbf{x})$ 。这里之所以考虑将  $p(\tilde{\mathbf{x}}_1, \tilde{\mathbf{x}}_2)$  作为融合优化指标, 是由于两局部估计误差  $\tilde{\mathbf{x}}_1$  和  $\tilde{\mathbf{x}}_2$  与目标的状态估计  $\hat{\mathbf{x}}$  具有相关性 (不独立), 因此若采用严格贝叶斯意义下的似然函数  $L(\hat{\mathbf{x}}_1, \hat{\mathbf{x}}_2 | \mathbf{x})$ , 在计算上存在较大困难。采用联合似然函数  $p(\hat{\mathbf{x}}_1 - \mathbf{x}, \hat{\mathbf{x}}_2 - \mathbf{x})$  作为优化指标也可以理解为: 将融合状态  $\mathbf{x}$  作为需要确定的一个不变参数, 将其作为该联合概率密度函数的自变量进行优化获取。本章后面几节基于后验概率和似然函数的严格贝叶斯意义下的融合准则与这里描述的交叉协方差融合准则一样, 都存在由于共用初始条件和共用过程噪声产生的交叉协方差矩阵  $\mathbf{V}_{12}$ 。

如果忽略交叉协方差  $\mathbf{V}_{ij} (i \neq j)$ , 则式 (6.15) 成为

$$\mathbf{w}_i = \mathbf{V}_j (\mathbf{V}_1 + \mathbf{V}_2)^{-1} = (\mathbf{V}_1^{-1} + \mathbf{V}_2^{-1}) \mathbf{V}_i^{-1} \quad i=1, 2 \quad j=3-i \quad (6.18)$$

于是式 (6.14) 成为

$$\begin{aligned} \mathbf{V}_F^{-1} &= \mathbf{V}_1^{-1} + \mathbf{V}_2^{-1} \\ \mathbf{V}_F^{-1} \hat{\mathbf{x}}_F &= \mathbf{V}_1^{-1} \hat{\mathbf{x}}_1 + \mathbf{V}_2^{-1} \hat{\mathbf{x}}_2 \end{aligned} \quad (6.19)$$

这就是简单的凸组合规则, 又称为自然融合 (Naive Fusion) 准则<sup>[12]</sup>。该准则也称为 Speyer 融合准则, 因其在 Speyer 的论文<sup>[59]</sup>中首次出现。

我们注意到, 由于  $\det \begin{bmatrix} \mathbf{V}_1 & \mathbf{V}_{12} \\ \mathbf{V}_{12}^T & \mathbf{V}_2 \end{bmatrix} = \det(\mathbf{V}_1 - \mathbf{V}_{12} \mathbf{V}_2^{-1} \mathbf{V}_{12}^T) \cdot \det(\mathbf{V}_2)$ , 因此忽略交叉协方差即

$\mathbf{V}_{12} = \mathbf{0}$ , 意味着两局部估计的联合误差协方差矩阵  $\begin{bmatrix} \mathbf{V}_1 & \mathbf{V}_{12} \\ \mathbf{V}_{12}^T & \mathbf{V}_2 \end{bmatrix}$  所定义的误差椭圆域增大为

$\begin{bmatrix} \mathbf{V}_1 & \mathbf{0} \\ \mathbf{0} & \mathbf{V}_2 \end{bmatrix}$  定义的误差椭圆域。也就是说, 通过增大融合误差协方差椭圆能够对交叉协方差融合

准则 (6.14)~(6.16) 进行简化, 但与交叉协方差融合准则真实的融合估计误差协方差矩阵 (6.16) 相比, 该简化的融合准则下的融合估计误差协方差矩阵  $\mathbf{V}_F = (\mathbf{V}_1^{-1} + \mathbf{V}_2^{-1})^{-1} = \mathbf{V}_1 - \mathbf{V}_1 (\mathbf{V}_1 + \mathbf{V}_2)^{-1} \mathbf{V}_1$  并不真实, 而是过于有利, 因此某些应用问题并不敢采用。

## 2. 小航迹 (Tracklet) 融合准则

线性高斯分布情况的小航迹融合准则融合公式定义为<sup>[16]</sup>

$$\begin{aligned} \mathbf{w}_i &= \mathbf{V}_F \mathbf{V}_i^{-1} \quad i=1, 2 \\ \mathbf{w}_0 &= -\mathbf{V}_F \bar{\mathbf{V}}^{-1} = \mathbf{I} - \mathbf{w}_1 - \mathbf{w}_2 \end{aligned} \quad (6.20)$$

或

$$\begin{aligned} \mathbf{V}_F^{-1} \hat{\mathbf{x}}_F &= \mathbf{V}_1^{-1} \hat{\mathbf{x}}_1 + \mathbf{V}_2^{-1} \hat{\mathbf{x}}_2 - \bar{\mathbf{V}}^{-1} \bar{\mathbf{x}} \\ \mathbf{V}_F^{-1} &= \mathbf{V}_1^{-1} + \mathbf{V}_2^{-1} - \bar{\mathbf{V}}^{-1} \end{aligned} \quad (6.21)$$

式中,  $\bar{V} = E[(\bar{\mathbf{x}} - \mathbf{x})(\bar{\mathbf{x}} - \mathbf{x})^T]$  是先验估计误差协方差矩阵。

小航迹融合准则考虑去除两跟踪源共用先验信息引起的相关性, 通过融合两局部分布密度获得全局分布密度, 因此是统计分布意义下的最优, 其通用定义是<sup>[17, 20, 22]</sup>:

$$\hat{p}_F(\mathbf{x}) = C^{-1} \hat{p}_1(\mathbf{x}) \hat{p}_2(\mathbf{x}) / \bar{p}(\mathbf{x}) \quad (6.22)$$

式中,  $\hat{p}_1(\mathbf{x}) = p(\mathbf{x} / (\mathbf{z}_{1k})_{k=1}^{N_1})$ ,  $\hat{p}_2(\mathbf{x}) = p(\mathbf{x} / (\mathbf{z}_{2k})_{k=1}^{N_2})$  分别是两个跟踪源基于各自测量的目标状态的后验分布密度估计;  $\bar{p}(\mathbf{x})$  是该目标的先验概率密度, 位于式 (6.22) 右端分母位置, 表示作为两跟踪源的共用信息予以去除一次;  $C$  是归一化常数。公式 (6.22) 适用于高密度目标和杂波空间中的任何 (通常是非高斯的) 分布情况。

我们注意到, 若目标运动状态是非确定的, 即动态方程 (6.3) 噪声系数  $B(t) \neq 0$ , 则采用式 (6.10) 进行先验误差协方差矩阵外推受该共用过程噪声的影响, 因此  $\hat{p}_1(\mathbf{x})$ 、 $\hat{p}_2(\mathbf{x})$  与  $\hat{p}_F(\mathbf{x})$  之间具有相关性, 这样, 小航迹融合准则在基于两跟踪源测量的后验状态估计  $E(\mathbf{x} / (\mathbf{z}_{1k})_{k=1}^{N_1} (\mathbf{z}_{2k})_{k=1}^{N_2})$  意义下可能并不精确, 故这里给出的融合估计误差协方差矩阵  $V_F = (V_1^{-1} + V_2^{-1} - \bar{V}^{-1})^{-1}$  将不是真实的, 很可能是过于不利或过于有利的。

融合准则式 (6.21) 可以分解为

$$\begin{cases} V_F^{-1} \hat{\mathbf{x}}_F = \bar{V}^{-1} \bar{\mathbf{x}} + \tilde{V}_1^{-1} \mathbf{z}_1 + \tilde{V}_2^{-1} \mathbf{z}_2 \\ V_F^{-1} = \bar{V}^{-1} + \tilde{V}_1^{-1} + \tilde{V}_2^{-1} \end{cases} \quad (6.23)$$

和

$$\begin{cases} \tilde{V}_i^{-1} \mathbf{z}_i = V_i^{-1} \hat{\mathbf{x}} - \bar{V}^{-1} \bar{\mathbf{x}} & i=1,2 \\ \tilde{V}_i^{-1} = V_i^{-1} - \bar{V}^{-1} & i=1,2 \end{cases} \quad (6.24)$$

事实上, 将式 (6.24) 代入式 (6.23) 即可得到小航迹融合准则式 (6.21)。这里引入了  $\hat{\mathbf{x}}_1, \hat{\mathbf{x}}_2$  与  $\hat{\mathbf{x}}_F$  之间的中间变量  $\mathbf{z}_1, \mathbf{z}_2$ , 从而解除了由于共用先验信息  $(\bar{\mathbf{x}}, \bar{V})$  引起的相关性。只要注意在代换变量  $(\mathbf{z}_i, \tilde{V}_i) i=1,2$  下, 式 (6.23) 成为相互独立变量  $\mathbf{z}_1, \mathbf{z}_2, \bar{\mathbf{x}}$  的集中式融合公式, 即可看到这一点。式 (6.24) 定义的解除相关的中间变量  $\mathbf{z}_1$  和  $\mathbf{z}_2$  被称为等效测量或伪测量, 因其代替了产生局部估计  $\hat{\mathbf{x}}_1$  和  $\hat{\mathbf{x}}_2$  所使用的测量集合  $\{\mathbf{z}_{1k}\}_{k=1}^{N_1}$  和  $\{\mathbf{z}_{2k}\}_{k=1}^{N_2}$ , 该测量集合可以是一个航迹段即一条航迹的一部分, 可以小到一个高斯分布单一航迹点, 也可以大到一条全航迹<sup>[8,47,26,27]</sup>, 这就是我们把融合准则式 (6.21) 称为小航迹融合准则的原因。用伪测量  $\mathbf{z}_1, \mathbf{z}_2$  解除相关的原理是在其定义式 (6.24) 中去除共用先验估计  $\bar{\mathbf{x}}$  及其协方差  $\bar{V}$ 。这样一来, 式 (6.23) 可以采用任何相互独立信息的集中式融合公式实现。由于式 (6.23) 是递推滤波的费舍尔 (Fisher) 信息矩阵形式, 因此, 带有式 (6.24) 的式 (6.23) 的分布式融合算法有时被称为信息滤波或信息矩阵滤波<sup>[14]</sup>。

式 (6.24) 又被称为解相关公式, 它为我们提供了用一个配对  $(\mathbf{z}_i, \tilde{V}_i) i=1,2$  表示一条小航迹或一个航迹段的方法, 该配对由等效测量及测量误差协方差矩阵组成, 可等价于  $(\tilde{V}_i^{-1} \mathbf{z}_i, \tilde{V}_i^{-1})$ , 他们实际上是两跟踪源原始测量集合  $\{\mathbf{z}_{1k}\}_{k=1}^{N_1}$  和  $\{\mathbf{z}_{2k}\}_{k=1}^{N_2}$  的充分统计量。使用式 (6.24) 近似表示信息的条件独立配对  $(\mathbf{z}_i, \tilde{V}_i)$  或  $(\tilde{V}_i^{-1} \mathbf{z}_i, \tilde{V}_i^{-1}) i=1,2$  的分布式航迹融合算法又称为信道滤波<sup>[29, 56]</sup>, 因其酷似从以通信信道最近一次通信提供的三组条件独立信息进行组合。

### 3. 极小方差融合准则

设  $\hat{\mathbf{x}}_F = E(\mathbf{x} | \hat{\mathbf{x}}_1, \hat{\mathbf{x}}_2)$  是在给出两个局部估计  $\hat{\mathbf{x}}_1, \hat{\mathbf{x}}_2$  的情况下, 融合时刻  $t_F$  的目标状态  $\mathbf{x} = \mathbf{x}(t_F)$  的条件期望。极小方差估计  $\hat{\mathbf{x}}_F$  在所有可能定义的测量函数所产生的估计  $\hat{\mathbf{x}}$  中能够使期望的估计误差方差  $\text{Var}(\hat{\mathbf{x}} - \mathbf{x} | \hat{\mathbf{x}}_1, \hat{\mathbf{x}}_2) = E(\|\hat{\mathbf{x}} - \mathbf{x}\|^2 | \hat{\mathbf{x}}_1, \hat{\mathbf{x}}_2)$  达极小<sup>[57]</sup>。对于高斯分布问题, 极小方差估计也是以  $\hat{\mathbf{x}}_1, \hat{\mathbf{x}}_2$  为条件的极大后验估计。由式 (6.7) 和式 (6.8) 给出的通用线性组合形式, 极小方差融合准则可定义为

$$\begin{cases} \hat{\mathbf{x}} = \mathbf{w}_0 \bar{\mathbf{x}} + \mathbf{w}_1 \hat{\mathbf{x}}_1 + \mathbf{w}_2 \hat{\mathbf{x}}_2 \\ (\mathbf{w}_1, \mathbf{w}_2) = \mathbf{V}_{xz} \mathbf{V}_{zz}^{-1}, \quad \mathbf{w}_0 = \mathbf{I} - \mathbf{w}_1 - \mathbf{w}_2 \end{cases} \quad (6.25)$$

$\mathbf{Z} = (\hat{\mathbf{x}}_1^T, \hat{\mathbf{x}}_2^T)^T$  是两局部状态估计构成的融合输入增广向量 (或被称为测量向量), 其联合误差协方差矩阵为

$$\mathbf{V}_{zz} = \text{cov}(\tilde{\mathbf{Z}}, \tilde{\mathbf{Z}}^T) = \begin{bmatrix} \mathbf{V}_1 + \bar{\mathbf{V}} - \mathbf{V}_{01}^T - \mathbf{V}_{01} & \mathbf{V}_{12} + \bar{\mathbf{V}} - \mathbf{V}_{01}^T - \mathbf{V}_{02} \\ \mathbf{V}_{12}^T + \bar{\mathbf{V}} - \mathbf{V}_{02}^T - \mathbf{V}_{01} & \mathbf{V}_2 + \bar{\mathbf{V}} - \mathbf{V}_{02}^T - \mathbf{V}_{02} \end{bmatrix} \quad (6.26)$$

目标状态的先验估计误差  $\hat{\mathbf{x}}$  与输入的增广向量  $\mathbf{Z}$  的估计误差  $\tilde{\mathbf{Z}}$  的交叉协方差为

$$\mathbf{V}_{xz} = \text{cov}(\tilde{\mathbf{x}}, \tilde{\mathbf{Z}}^T) = [\bar{\mathbf{V}} - \mathbf{V}_{01} \quad \bar{\mathbf{V}} - \mathbf{V}_{02}] \quad (6.27)$$

将式 (6.26) 和式 (6.27) 导出如下:

注意到  $\hat{\mathbf{x}}_i - \bar{\mathbf{x}} = \hat{\mathbf{x}}_i - \mathbf{x} + \mathbf{x} - \bar{\mathbf{x}} = \tilde{\mathbf{x}}_i - (\bar{\mathbf{x}} - \mathbf{x})$ , 于是局部估计  $\hat{\mathbf{x}}_1, \hat{\mathbf{x}}_2$  与先验状态  $\bar{\mathbf{x}}$  的误差的交叉协方差为

$$E[(\hat{\mathbf{x}}_i - \bar{\mathbf{x}})(\hat{\mathbf{x}}_j - \bar{\mathbf{x}})^T] = \mathbf{V}_{ij} + \bar{\mathbf{V}} - \mathbf{V}_{0i}^T - \mathbf{V}_{0j} \quad i, j = 1, 2 \quad i \neq j$$

于是得

$$\begin{aligned} \mathbf{V}_{zz} &= \text{cov} \left\{ \begin{pmatrix} \hat{\mathbf{x}}_1 - \bar{\mathbf{x}} \\ \hat{\mathbf{x}}_2 - \bar{\mathbf{x}} \end{pmatrix}, [(\hat{\mathbf{x}}_1 - \bar{\mathbf{x}})^T \quad (\hat{\mathbf{x}}_2 - \bar{\mathbf{x}})^T] \right\} \\ &= \begin{bmatrix} \text{cov}[(\hat{\mathbf{x}}_1 - \bar{\mathbf{x}}), (\hat{\mathbf{x}}_1 - \bar{\mathbf{x}})^T] & \text{cov}[(\hat{\mathbf{x}}_1 - \bar{\mathbf{x}}), (\hat{\mathbf{x}}_2 - \bar{\mathbf{x}})^T] \\ \text{cov}[(\hat{\mathbf{x}}_2 - \bar{\mathbf{x}}), (\hat{\mathbf{x}}_1 - \bar{\mathbf{x}})^T] & \text{cov}[(\hat{\mathbf{x}}_2 - \bar{\mathbf{x}}), (\hat{\mathbf{x}}_2 - \bar{\mathbf{x}})^T] \end{bmatrix} \\ &= \begin{bmatrix} \mathbf{V}_1 + \bar{\mathbf{V}} - \mathbf{V}_{01}^T - \mathbf{V}_{01} & \mathbf{V}_{12} + \bar{\mathbf{V}} - \mathbf{V}_{01}^T - \mathbf{V}_{02} \\ \mathbf{V}_{12}^T + \bar{\mathbf{V}} - \mathbf{V}_{02}^T - \mathbf{V}_{01} & \mathbf{V}_2 + \bar{\mathbf{V}} - \mathbf{V}_{02}^T - \mathbf{V}_{02} \end{bmatrix} \quad \mathbf{V}_{ii} = \mathbf{V}_i \quad i = 1, 2 \end{aligned}$$

此即式 (6.26), 其中  $\mathbf{V}_{ij} (i \neq j)$  按 6.3.1 节式 (6.13) 计算。再注意  $\mathbf{x} - \bar{\mathbf{x}} = -(\bar{\mathbf{x}} - \mathbf{x})$ , 于是目标状态  $\mathbf{x}$  的局部估计误差  $\tilde{\mathbf{x}}_i = \hat{\mathbf{x}}_i - \mathbf{x}$  与先验状态  $\bar{\mathbf{x}}$  的估计误差  $\bar{\mathbf{x}} - \mathbf{x}$  的交叉协方差为

$$\text{cov}[(\mathbf{x} - \bar{\mathbf{x}})(\hat{\mathbf{x}}_i - \bar{\mathbf{x}})^T] = \text{cov}[-(\bar{\mathbf{x}} - \mathbf{x}), (\hat{\mathbf{x}}_i - \mathbf{x}) - (\bar{\mathbf{x}} - \mathbf{x})] = \bar{\mathbf{V}} - \mathbf{V}_{0i} \quad i = 1, 2$$

于是得

$$\begin{aligned} \mathbf{V}_{xz} &= \text{cov} \left[ (\mathbf{x} - \bar{\mathbf{x}}), \begin{pmatrix} \hat{\mathbf{x}}_1 - \bar{\mathbf{x}} \\ \hat{\mathbf{x}}_2 - \bar{\mathbf{x}} \end{pmatrix}^T \right] = (\text{cov}[(\mathbf{x} - \bar{\mathbf{x}}), (\hat{\mathbf{x}}_1 - \bar{\mathbf{x}})^T], \text{cov}[(\mathbf{x} - \bar{\mathbf{x}}), (\hat{\mathbf{x}}_2 - \bar{\mathbf{x}})^T]) \\ &= (\bar{\mathbf{V}} - \mathbf{V}_{01}, \bar{\mathbf{V}} - \mathbf{V}_{02}) \end{aligned}$$

这样一来, 极小方差融合准则可以重写为下述基于融合状态及其估计误差协方差的表达式:

$$\begin{cases} \hat{\mathbf{x}}_F = \bar{\mathbf{x}} + \mathbf{V}_{xz} \mathbf{V}_{zz}^{-1} (\mathbf{Z} - \bar{\mathbf{Z}}) \\ \mathbf{V}_F = \bar{\mathbf{V}} - \mathbf{V}_{xz} \mathbf{V}_{zz}^{-1} \mathbf{V}_{zx} \end{cases} \quad (6.28)$$

式中,  $\bar{\mathbf{x}}$  和  $\bar{\mathbf{V}}$  是融合输入的先验状态及其误差协方差,  $\mathbf{Z} = (\hat{\mathbf{x}}_1^T, \hat{\mathbf{x}}_2^T)^T$  是融合输入的两局部估计的增广向量,  $\mathbf{V}_{zz}$ 、 $\mathbf{V}_{zx}$  分别如式 (6.26) 和式 (6.27) 所示。

由此可见, 极小方差融合准则既考虑了共用过程噪声引起的隐式相关性 ( $\mathbf{V}_{12}, \mathbf{V}_{21}$ ), 又考虑了先验信息引起的显式相关性 ( $\bar{\mathbf{V}}, \mathbf{V}_{01}, \mathbf{V}_{02}$ ), 而 Bar Shalom—Campo 的交叉协方差 (CC) 融合准则仅考虑了共用过程噪声引起的相关性, 小航迹融合准则只考虑了先验信息 ( $\bar{\mathbf{x}}, \bar{\mathbf{V}}$ ) 引起的相关性。极小方差融合准则给出了基于两局部估计的最优估计, 其融合误差协方差矩阵  $\mathbf{V}_F$  是真实的, 而小航迹融合准则和交叉协方差融合准则产生的估计误差协方差矩阵是不真实的 (过于有利) 的。

文献[63, 44]通过在约束  $\mathbf{w}_0 + \mathbf{w}_1 + \mathbf{w}_2 = \mathbf{I}$  的情况下使融合估计误差协方差极小化来选择权值向量  $\mathbf{w}_0$ 、 $\mathbf{w}_1$ 、 $\mathbf{w}_2$ , 此时极小方差准则在理论上能够产生最佳线性无偏估计 (BLUE), 故又可将 MV 准则称为 BLUE 准则。然而这是一件很困难的事情, 在应用上只能采用近似方法选择权值 ( $\mathbf{w}_0, \mathbf{w}_1, \mathbf{w}_2$ )。显然, 交叉协方差融合准则可以作为约束条件  $\mathbf{w}_0 = 0, \mathbf{w}_1 + \mathbf{w}_2 = \mathbf{I}$  情况下的极小方差融合准则, 可以通过使估计误差协方差矩阵极小化来选择权值向量 ( $\mathbf{w}_1, \mathbf{w}_2$ )。

#### 4. 贝叶斯极大似然融合准则

贝叶斯极大似然 (BML) 融合准则通过使严格贝叶斯意义下的似然函数达极大来确定目标状态估计及估计误差协方差。在一次航迹融合中, 用前文中所定义的两个输入的局部估计作为测量向量  $\mathbf{Z} = (\hat{\mathbf{x}}_1^T, \hat{\mathbf{x}}_2^T)^T$ , 先验信息为  $\bar{\mathbf{x}}$  和  $\bar{\mathbf{V}}$ 。由式 (6.28) 可知, 高斯分布之下的极小方差估计为

$$\begin{cases} \hat{\mathbf{x}} = \bar{\mathbf{x}} + \mathbf{V}_{xz} \mathbf{V}_{zz}^{-1} (\mathbf{Z} - \bar{\mathbf{Z}}) \\ \hat{\mathbf{V}} = \bar{\mathbf{V}} - \mathbf{V}_{xz} \mathbf{V}_{zz}^{-1} \mathbf{V}_{zx} \end{cases} \quad (6.29)$$

由于在给定目标状态  $\mathbf{x}$  的情况下, 测量向量是  $\mathbf{Z}$  的条件概率密度也是高斯分布:  $p(\mathbf{Z} | \mathbf{x}) = g(\mathbf{Z} - \hat{\mathbf{Z}}, \hat{\mathbf{V}}_{zz})$ , 故调换式 (6.29) 中  $\mathbf{x}$  与  $\mathbf{Z}$  的位置可以得到:

$$\begin{cases} \hat{\mathbf{Z}} = \bar{\mathbf{Z}} + \mathbf{V}_{zx} \bar{\mathbf{V}}^{-1} (\mathbf{x} - \bar{\mathbf{x}}) \\ \hat{\mathbf{V}} = \mathbf{V}_{zz} - \mathbf{V}_{zx} \bar{\mathbf{V}}^{-1} \mathbf{V}_{xz} \end{cases} \quad (6.30)$$

式中,  $\mathbf{V}_{zz}$  是式 (6.26) 所示的测量误差向量方差矩阵,  $\mathbf{V}_{xz} = \mathbf{V}_{xz}^{-1}$  是式 (6.27) 所示的目标状态向量与测量向量的交叉协方差矩阵。

在给出测量向量  $\mathbf{Z} = (\hat{\mathbf{x}}_1^T, \hat{\mathbf{x}}_2^T)^T$  的条件下, 将似然函数  $p(\mathbf{Z} | \mathbf{x})$  作为状态  $\mathbf{x}$  的函数, 则使其达极大的融合状态估计  $\hat{\mathbf{x}}_F$  及其误差协方差为

$$\begin{cases} \hat{\mathbf{x}}_F = \bar{\mathbf{x}} + \bar{\mathbf{V}} (\mathbf{V}_{xz} \mathbf{V}_{zz}^{-1} \mathbf{V}_{zx})^{-1} \mathbf{V}_{xz} \mathbf{V}_{zz}^{-1} (\mathbf{Z} - \bar{\mathbf{Z}}) \\ \mathbf{V}_F = \bar{\mathbf{V}} - (\mathbf{V}_{xz} \mathbf{V}_{zz}^{-1} \mathbf{V}_{zx})^{-1} \mathbf{V}_{xz} \mathbf{V}_{zz}^{-1} \mathbf{V}_{zx} \end{cases} \quad (6.31)$$

这相当于在极小方差 (MV) 融合准则中, 将融合权重  $[\mathbf{w}_1, \mathbf{w}_2] = \mathbf{V}_{xz} \mathbf{V}_{zz}^{-1}$ ,  $\mathbf{w}_0 = \mathbf{I} - \mathbf{w}_1 - \mathbf{w}_2$  代换为  $[\mathbf{w}_1, \mathbf{w}_2] = \bar{\mathbf{V}} \mathbf{M} \mathbf{V}_{xz} \mathbf{V}_{zz}^{-1}$ ,  $\mathbf{M} = (\mathbf{V}_{xz} \mathbf{V}_{zz}^{-1} \mathbf{V}_{zx})^{-1}$ ,  $\mathbf{w}_0 = \mathbf{I} - \mathbf{w}_1 - \mathbf{w}_2$ 。

由于这里的似然函数  $p(\mathbf{Z} | \mathbf{x})$  和状态后验分布  $p(\mathbf{x} | \mathbf{Z})$  都是严格贝叶斯意义下的高斯

分布, 故式(6.31)定义的融合规则被称为贝叶斯极大似然准则或 BML 准则。

### 5. 协方差交集融合准则

协方差交集 (CI) 融合方法是当两个局部估计误差的交叉协方差未知或无法得到时, 融合两个估计—协方差对  $(\hat{\mathbf{x}}_1, \mathbf{V}_1)$  与  $(\hat{\mathbf{x}}_2, \mathbf{V}_2)$  的一种方法, 它是一种启发式 (尝试性) 方法, 用来调节由于忽略交叉协方差  $\mathbf{V}_{ij} (i \neq j)$  产生的自然 (naive) 融合或 Speyer 融合中的共用简单权重, 融合公式为

$$\begin{cases} \mathbf{V}_F^{-1} \hat{\mathbf{x}}_F = \alpha \mathbf{V}_1^{-1} \hat{\mathbf{x}}_1 + (1-\alpha) \mathbf{V}_2^{-1} \hat{\mathbf{x}}_2 \\ \mathbf{V}_F^{-1} = \alpha \mathbf{V}_1^{-1} + (1-\alpha) \mathbf{V}_2^{-1} \end{cases} \quad (6.32)$$

式中, 共用标量参数  $\alpha \in [0, 1]$ , 相当于在通用线性加权融合公式(6.7)中, 各权向量为

$$\mathbf{w}_0 = 0, \quad \mathbf{w}_1 = \alpha \mathbf{V}_F \mathbf{V}_1^{-1}, \quad \mathbf{w}_2 = (1-\alpha) \mathbf{V}_F \mathbf{V}_2^{-1}$$

融合公式(6.32)可视为在下述高斯分布下, 概率密度的指数加权融合准则:

$$\hat{p}_F(\mathbf{x}) = \frac{p_1(\mathbf{x})^\alpha p_2(\mathbf{x})^{1-\alpha}}{\int_E p_1(\mathbf{x}')^\alpha p_2(\mathbf{x}')^{1-\alpha} d\mathbf{x}'} \quad (6.33)$$

该式右侧分母是 Chernoff 信息<sup>[35, 37]</sup>, 故又被称为 Chernoff 融合准则<sup>[35, 37]</sup>。

协方差交集 (CI) 在概念上是指全局融合航迹误差协方差椭圆  $\left\{ \mathbf{x} \in E \left[ \|\mathbf{x}\|_{\mathbf{V}_F^{-1}}^2 \right] \leq \sigma^2 \right\}$  ( $\sigma^2 > 0$ ,  $\|\mathbf{x}\|_{\mathbf{V}_F^{-1}}^2$  表示标准差  $\sigma$  的椭圆边界曲线) 来自两个具有同样标准差边界的局部航迹的误差协方差椭圆的交集<sup>[54, 55, 38]</sup>, 该概念没有说明它们之间的关系。通常, 融合误差椭圆并不包含在两个局部估计误差椭圆的交集之中, 而是包含了两局部误差椭圆的交集, 如图 6.4 所示 (见参考文献[67])。

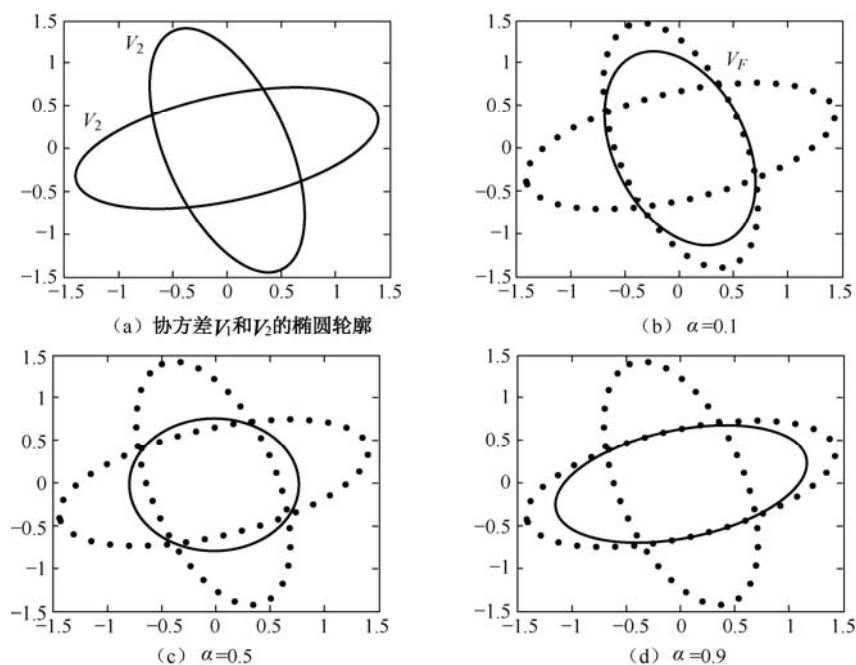


图 6.4 不同  $\alpha$  取值下的  $\mathbf{V}_F$  椭圆与  $\mathbf{V}_1$ 、 $\mathbf{V}_2$  椭圆的关系

从图6.4 (b) ~ (d) 中可以看出：不同的  $\alpha$  取值获得的融合误差协方差  $V_F$  椭圆（实线）都覆盖了两个局部估计误差  $V_1$ 、 $V_2$  椭圆（虚线）的交集。

在协方差交集（CI）融合中，选择标量权值参数  $\alpha \in [0, 1]$  通常采用下述两个准则：

① 最小熵融合准则。

最小熵融合准则又称为香农（Shannon）融合准则<sup>[12]</sup>。考虑连续随机变量形式的信息熵，即下述的融合概率分布的连续熵（也可离散化）：

$$H(\hat{p}_F) = - \int_E \ln[\hat{p}_F(\mathbf{x})] \hat{p}_F(\mathbf{x}) d\mathbf{x} \quad (6.34)$$

使式（6.34）达极小来选择标量权值  $\alpha$  的协方差交集（CI）融合准则被称为最小熵融合准则。 $\hat{p}_F$  是带有 CI 协方差矩阵  $V_F$  的高斯分布：

$$\hat{p}_F(\mathbf{x}) = [\det(2\pi V_F)]^{-\frac{\dim(E)}{2}} \cdot \exp\left[-\frac{1}{2}(\mathbf{x} - \hat{\mathbf{x}}_F) V_F^{-1} (\mathbf{x} - \hat{\mathbf{x}}_F)^T\right] \quad (6.35)$$

式中， $\dim(E)$  为状态空间  $E$  的维数。此时，该概率分布的连续熵（6.34）成为

$$H(\hat{p}_F) = \frac{1}{2} \ln[\det(2\pi V_F) + \dim(E)] \quad (6.36)$$

这样一来，使  $H(\hat{p}_F)$  极小化就变成使行列式  $\det(V_F)$  极小化。于是最小熵融合准则就变成使  $\det(V_F)$  达极小确定标量权值  $\alpha$  的 CI 融合准则。

② 均方误差极小化融合准则。

均方误差极小化融合准则的概念是使式（6.32）第二式所定义的融合误差协方差矩阵  $V_F$  的迹极小化来确定标量权值参数  $\hat{\alpha}$ ：

$$\hat{\alpha} = \arg \min \{ \text{tr}[\alpha V_1^{-1} + (1 - \alpha) V_2^{-1}]^{-1} \} \quad (6.37)$$

值得注意的是，该式确定的最优标量权值  $\hat{\alpha}$  能够使 CI 融合的增益矩阵  $\mathbf{w}_1$  和  $\mathbf{w}_2$  的下述函数达极小<sup>[15]</sup>，即：

$$\hat{\alpha} = \arg \min \{ \sqrt{\text{tr}(\mathbf{w}_1 V_1 \mathbf{w}_1^T)} + \sqrt{\text{tr}(\mathbf{w}_2 V_2 \mathbf{w}_2^T)} \} \quad 0 \leq \alpha \leq 1 \quad (6.38)$$

式中， $\mathbf{w}_1 = \hat{\alpha} V_F V_1^{-1}$ ， $\mathbf{w}_2 = (1 - \hat{\alpha}) V_F V_2^{-1}$  是 CI 融合对两局部估计的最优增益矩阵，它满足无偏条件  $\mathbf{w}_1 + \mathbf{w}_2 = \mathbf{I}$ 。该结论在实现全局融合对两局部估计的最优反馈控制上具有很好的效果。由于该结论是由 Chen—Arambel—Mehra 导出的<sup>[48]</sup>，故将带有该  $\hat{\alpha}$  的自然（凸交集）融合准则称为 Chen—Arambel—Mehra 融合准则。

### 6.3.3 航迹融合准则性能评估基准

#### 1. 确定融合准则评估基准考虑的因素

评估迄今为止所提出的各项航迹融合准则性能的优劣需要确定一个统一的基准，该基准的选择需考虑下述几个因素：

① 已有航迹融合准则的相对性。

已有的航迹融合准则是由各局部航迹估计（显式的状态估计及其协方差或隐式的统计分布）在不同优化基准，如最小方差（MV）、极大似然（ML）、极大后验（MAP）等意义下

采用不同的融合方法获得的,这些优化基准是相对的,其估计结果的优劣比较缺乏统一的基准。

## ② 使用测量信息的充分程度。

众所周知,各项航迹融合准则都涉及对传感器测量信息的使用,在某种意义上,使用的测量信息的多少比各项准则所采用的融合方法对航迹融合性能起着更重要的作用。特别是当目标动态的非确定性超出预设的过程噪声强度时,各项准则下的局部航迹都不是测量集合的充分统计量,此时无法确定各融合准则性能的优劣。

## ③ 集中式融合性能的优势。

直接使用各传感器测量的集中式融合不损失任何测量信息,即其对测量信息的使用是充分的。在满足传统假设(如传感器独立观测、状态与噪声相互独立等)和给定优化基准的情况下,集中式融合结果可以认为是各传感器测量的充分统计量,因此其跟踪性能优于目前已有的所有分布式航迹融合准则。

## ④ 分布式航迹融合性能向集中式融合逼近。

在关于目标航迹的分布式融合准则和方法的长期研究过程中,人们最近才认识到,通过融合或组合各局部航迹估计能够重构出类似于集中式融合的全局最优航迹估计结果。在具有不确定性动态和全速率通信的分布环境下,这样的重构已经实现。我们已注意到,文献[41, 42, 32, 33]给出了通过融合各局部航迹估计重构全局最优航迹的融合准则,称为 Koch—Govaers 准则。

综上所述,我们可以得到如下结论:各项航迹融合准则性能的优劣主要取决于其使用的传感器测量信息量,因此,各航迹融合准则性能的优劣无法直接进行比较,包括与其中某个优化程度较高的准则(如 MV 准则)比较,而应该与传统集中式目标跟踪性能进行比较。由于 Koch—Govaers 准则指出了在具有异步通信和全速率通信环境中每个局部站点按测量周期逐周期融合生成目标局部航迹并传输给全局站点,全局站点按式(6.11)进行时序变换后对各局部航迹进行融合,生成全局融合航迹并反馈给局部站点,这样就能够产生近似集中式目标跟踪的全局最优航迹。因此, Koch—Govaers 准则也可以作为各航迹融合准则性能比较的基准。

## 2. Koch—Govaers 融合准则

下面介绍可以作为评估基准的 Koch—Govaers 融合准则的实现方法。

### ① Koch—Govaers 融合原理。

该融合准则描述目标连续跟踪中相邻两个融合周期两传感器航迹状态估计之间的递推关系。由贝叶斯公式:

$$p_{k|k}(\mathbf{x} | \mathbf{Z}^k) = \frac{p_k(\mathbf{z}_k | \mathbf{x}) p_{k|k-1}(\mathbf{x} | \mathbf{Z}^{k-1})}{p_k(\mathbf{z}_k | \mathbf{Z}^{k-1})}$$

当两传感器独立观测时,其局部估计之间也相互独立,于是可得到两局部航迹(包括先验航迹)的融合公式(见第9章 9.2.2 节):



$$p_{k|k}(\mathbf{x}|\mathbf{Z}^k) \propto \frac{p_{k|k}^1(\mathbf{x}|\mathbf{Z}_1^k)p_{k|k}^2(\mathbf{x}|\mathbf{Z}_2^k)}{p_{k|k-1}^1(\mathbf{x}|\mathbf{Z}_1^{k-1})p_{k|k-1}^2(\mathbf{x}|\mathbf{Z}_2^{k-1})} \cdot p_{k|k-1}(\mathbf{x}|\mathbf{Z}^{k-1}) \quad (6.39)$$

式中,  $p_{k|k}(\mathbf{x}|\mathbf{Z}^k)$  是基于测量时刻  $T_k$  及之前所有测量的全局状态后验估计密度;

$p_{k|k}(\mathbf{x}|\mathbf{Z}^k)$  是基于测量时刻  $T_{k-1}$  及之前所有测量的  $T_k$  时刻全局状态预测密度, 作为全局先验航迹密度参与融合;

$p_{k|k}(\mathbf{x}|\mathbf{Z}^k)$  是基于测量时刻  $T_k$  及之前传感器  $i$  测量的局部状态后验密度 ( $i=1,2$ );

$p_{k|k}(\mathbf{x}|\mathbf{Z}^k)$  是基于测量时刻  $T_k$  及之前传感器  $i$  测量的  $T_k$  时刻局部状态预测密度 ( $i=1,2$ )。

两个局部预测密度位于式 (6.39) 的分母中, 表示去除一次重复使用。其中  $\{T_k\}_{k=1}^N$  ( $N \leq N_1 + N_2$ ) 是如 6.3.1 节给出的两传感器局部非同步测量时刻  $[\{t_{ik}\}_{k=1}^{N_i}]_{i=1,2}$  的统一排序集合, 如式 (6.40) 所示。

$$T_k \in \begin{cases} I_k \{1\} : T_k = t_{1k'} & \text{对应传感器1测量}\{\mathbf{z}_{1k'}\}_{k'=1}^{N_1} \text{中的某些}k' \\ I_k \{2\} : T_k = t_{2k'} & \text{对应传感器2测量}\{\mathbf{z}_{2k'}\}_{k'=1}^{N_2} \text{中的某些}k' \\ I_k \{1,2\} : T_k = t_{1k'} = t_{2k'} & \text{同时对应}\{\mathbf{z}_{1k'}\}_{k'=1}^{N_1} \text{和}\{\mathbf{z}_{2k'}\}_{k'=1}^{N_2} \text{中的某些}k' \end{cases} \quad (6.40)$$

## ② 融合输入信息。

Koch—Govaers 融合原理是各独立数据源的贝叶斯航迹融合公式 (6.39), 该公式要求每个传感器提供各自估计时刻  $t_{k'}$  的目标航迹预测和后验估计以及各自的误差协方差:

$$\begin{aligned} \bar{\mathbf{x}}_{ik} &= E[\mathbf{x}_{ik} | \{\mathbf{z}_{ik'}\}_{k'=1}^{k-1}], \quad \bar{\mathbf{V}}_k = \text{cov}[(\bar{\mathbf{x}}_{ik} - \mathbf{x}_k), (\bar{\mathbf{x}}_{ik} - \mathbf{x}_k)^T] \\ \hat{\mathbf{x}}_{ik} &= E[\mathbf{x}_{ik} | \{\mathbf{z}_{ik'}\}_{k'=1}^k], \quad \hat{\mathbf{V}}_k = \text{cov}[(\hat{\mathbf{x}}_{ik} - \mathbf{x}_k), (\hat{\mathbf{x}}_{ik} - \mathbf{x}_k)^T] \end{aligned} \quad i=1,2 \quad (6.41)$$

其中两局部航迹预测方差皆为  $\bar{\mathbf{V}}_k$ , 这是由于采用相同的状态转移方程所致。两传感器对全局统一估计时刻  $T_k$  的航迹预测状态和后验估计状态服从下述高斯分布:

$$p[\mathbf{x}(T_k) | \{\mathbf{z}_{ik'}\}_{k'=1}^{k-1}] = C_i^{-1} g[\mathbf{x}(T_k) - \bar{\mathbf{x}}_{ik}; \bar{\mathbf{V}}_k] \quad i=1,2 \quad (6.42)$$

$$p[\mathbf{x}(T_k) | \{\mathbf{z}_{ik'}\}_{k'=1}^k] = C_i^{-1} g[\mathbf{x}(T_k) - \hat{\mathbf{x}}_{ik}; \hat{\mathbf{V}}_k] \quad i=1,2 \quad (6.43)$$

## ③ 目标状态概率密度全局融合公式。

在独立高斯分布下, 全局站点基于 Koch—Govaers 方法融合获得的目标航迹预测概率密度为

$$p(\mathbf{x}(T_k) | \{\mathbf{z}_{ik'}\}_{k'=1}^{k-1}, t_{ik'} \leq T_{k-1}) = C^{-1} \prod_{i=1}^2 g(\mathbf{x}(T_k) - \bar{\mathbf{x}}_{ik}; \bar{\mathbf{V}}_k) \quad i=1,2 \quad (6.44)$$

融合的目标航迹后验概率密度为

$$p(\mathbf{x}(T_k) | \{\mathbf{z}_{ik'}\}_{k'=1}^k, t_{ik'} \leq T_k) = C'^{-1} \prod_{i=1}^2 g(\mathbf{x}(T_k) - \hat{\mathbf{x}}_{ik}; \hat{\mathbf{V}}_k) \quad i=1,2 \quad (6.45)$$

式 (6.44) 和式 (6.45) 中均值和协方差初值  $(\bar{\mathbf{x}}_{i0}, \bar{\mathbf{V}}_{i0})$  和  $(\hat{\mathbf{x}}_{i0}, \hat{\mathbf{V}}_{i0})$   $i=1,2$  可基于式 (6.41) 给出的两传感器局部航迹预测和后验估计值及相应误差协方差逆向递推确定。

## ④ 全局融合信息对局部融合的反馈控制。

在目标跟踪过程中, 按 (6.46) 和式 (6.47) 给出的反馈融合公式递推获取各融合时刻  $T_k$

目标的局部航迹预测和后验估计均值和误差协方差<sup>[42, 32, 33]</sup>, 其中对目标局部状态预测及其误差协方差的反馈融合递推计算如下:

$$\begin{cases} \bar{\mathbf{x}}_{ik} = 2\Phi(T_k, T_{k-1}) \left( \sum_{i'=1}^2 \hat{\mathbf{V}}_{i'(k-1)}^{-1} \right) \hat{\mathbf{V}}_{i'(k-1)} \hat{\mathbf{x}}_{i'(k-1)} \\ \bar{\mathbf{V}}_k = 2 \left( \Phi(T_k, T_{k-1}) \left( \sum_{i'=1}^2 \hat{\mathbf{V}}_{i'(k-1)}^{-1} \right)^{-1} \Phi(T_k, T_{k-1})^T + \mathbf{Q} \Phi(T_k, T_{k-1}) \right) \end{cases} \quad i=1,2 \quad (6.46)$$

式中,  $(\hat{\mathbf{x}}_{i(k-1)}, \hat{\mathbf{V}}_{i(k-1)})$  是  $T_{k-1}$  时刻传感器  $i$  的局部航迹后验估计及其误差协方差,  $\Phi(T_k, T_{k-1})$  是从  $T_{k-1}$  时刻到  $T_k$  时刻的目标状态转移矩阵,  $\mathbf{Q}$  为动态噪声密度协方差矩阵。

对目标局部航迹后验估计及其误差协方差的反馈融合递推计算如下:

$$\begin{cases} \hat{\mathbf{x}}_{ik} = \bar{\mathbf{x}}_{ik} + \mathbf{K}'_{ik} \mathbf{z}_{ik'} - \mathbf{H}_{ik'} \bar{\mathbf{x}}_{ik} \\ \hat{\mathbf{V}}_k = (\mathbf{I} - \mathbf{K}'_{ik'} \mathbf{H}_{ik'}) \bar{\mathbf{V}}_k \end{cases} \quad (6.47)$$

式中的时间下标  $k$  与  $k'$  按式 (6.40) 给出的  $T_k = t_{1k'}$  或  $T_k = t_{2k'}$  对应,  $\mathbf{z}_{ik'}$  是  $T_k(t_{ik'})$  时刻传感器  $i$  的目标测量值。式 (6.47) 中, 对于每个传感器  $i$  和对应的测量时刻  $T_k = t_{ik'}$ , 增益矩阵  $\mathbf{K}'_{ik}$  为

$$\mathbf{K}'_{ik} = \bar{\mathbf{V}}_{k-1} \mathbf{H}_{ik'}^T (\mathbf{H}_{ik'} \bar{\mathbf{V}}_{k-1} \mathbf{H}_{ik'}^T + \mathbf{R}_{ik'})^{-1} \quad i=1,2 \quad (6.48)$$

式中,  $\mathbf{H}_{ik'}$  和  $\mathbf{R}_{ik'}$  分别为传感器  $i$  在  $t_{ik'}$  时刻的测量变换矩阵和测量误差协方差矩阵。

当  $t_k > \max\{t_{N_i}\}$  时, 两传感器已无测量值, 故此时

$$\begin{cases} \hat{\mathbf{x}}_{ik} = \bar{\mathbf{x}}_{ik} \\ \hat{\mathbf{V}}_k = \bar{\mathbf{V}}_k \end{cases}$$

此式表示已不需要进行状态更新, 这类似于 6.3.1 节所描述的非同步测量交叉协方差递推计算中, 融合时刻  $t_F > T_N$  时只需要增加一个预测步骤, 因为此时  $(T_N, t_F)$  中已无测量值。

对于式 (6.46) ~ 式 (6.48) 需要说明的是: 对于式 (6.40) 中  $T_k \in I_k(1,2)$  的情况, 两传感器测量同时到来, 反馈融合预测公式 (6.46) 在每个反馈递推滤波步骤中仅使用了一次, 因每次仅将航迹估计反馈预测到这两个局部航迹下一测量同时到来的时刻。此时, 反馈融合更新公式 (6.47) 和式 (6.48) 需要应用 2 次, 以体现出基于预测航迹估计的两个同时到来的局部测量对各自局部航迹的反馈融合更新。

### 3. 几点说明

上述 Koch—Govaers 融合方法给出了向集中式跟踪性能逼近的分布式融合方法和条件, 其性能居于 6.3.2 节所描述的各航迹融合准则之上, 在将其作为 6.3.2 节所介绍的各种航迹融合准则的性能比较的基准时, 需要注意如下几点:

首先, 在递推滤波过程中, 由式 (6.41) 表示的基于传感器自身测量的局部状态预测估计  $\{\bar{\mathbf{x}}_{ik}\}_{i=1}^2$  和局部状态更新估计  $\{\bar{\mathbf{x}}_{ik}\}_{i=1}^2$  不一定是局部最优估计, 这是由于在给出初值之后, 在各航迹融合时刻  $T_k$  各局部估计都基于全局融合反馈公式 (6.46) ~ 式 (6.48) 再次进行更新。因此, 可以说 Koch—Govaers 融合方法是通过损失局部最优来获得全局最优的。实际上, 航迹融合公式 (6.46) ~ 式 (6.48) 相当于在两传感器自主结构中每个传感器设置的全局估

计器（详见后面 6.5.2 节中对图 6.11（b）自主结构融合信息图的描述）。也正因为如此，如果局部跟踪需要的话，可以在每个传感器站点再设置一个如图 6.11（b）所示的局部卡尔曼滤波估计器，其与式（6.46）～式（6.48）定义的该站点全局估计器并行工作，以在某种情况下（如全局估计误差协方差矩阵不真实）获得不受全局估计恶化影响的局部最优跟踪性能。

其次，从式（6.46）～式（6.48）可以看到，全局反馈预测和更新需要各传感器的局部更新估计协方差  $\hat{V}_{i(k-1)}$ ，包括自身和其他所有传感器的，以及其他局部处理器的计算协方差矩阵所需要的更广泛知识，这一要求显然过于苛刻。

第三，我们还要注意的，在分布式跟踪系统中，通常假设的线性高斯系统的所有估计误差（自身和交叉的）协方差矩阵及各关键参数，如卡尔曼滤波增益矩阵和更新估计误差协方差矩阵等都是确定性（非随机）的，因此在统计理论中，它们都假设为已知、可计算或作为问题定义（或陈述）的一部分。然而，在分布式网络环境中，交换这些知识需要有效的通信带宽，其可达性无法确定。在现实中，我们通常将这些知识用作系统设计参数，“预先传输”这些离线信息。否则，将每个局部观测的误差协方差矩阵实时传输给融合中心或其他局部站点可能要花费相当或超过传输所有测量的通信负荷，这是不能容忍的。此外，当系统的线性或高斯性存在疑问时，需使用扩展卡尔曼滤波，扩展的误差协方差矩阵可能出现数据相关问题，因此必须进行某些调整。这些问题将导致该最优的 Koch—Govaers 融合方法的算法仅在仿真实验情况下可行，而对于实际的网络环境，还有待于应用验证。因此在航迹融合准则的性能评估中，通常还是采用与集中式跟踪性能直接比较的方式。

## 6.4 一次航迹融合准则性能评估案例

### 6.4.1 案例剧情模型

为了展示各主要航迹融合准则的性能并进行比较，仿真案例所采用的剧情，即目标运动状态模型和传感器测量模型要具有一定代表性，与实际应用接近，并尽可能简单，同时能够产生我们要评估的各融合准则性能所需要的剧情。为此，我们选择四维（两维位置，两维速度）状态空间，采用下述 Ornstein—Uhlenbeck 模型（以下简称 O—U 模型），该模型的目标动态方程为

$$\frac{d}{dt} \begin{bmatrix} x \\ y \\ V_x \\ V_y \end{bmatrix} = \begin{bmatrix} 0_2 & I_2 \\ 0_2 & -\beta I_2 \end{bmatrix} \begin{bmatrix} x \\ y \\ V_x \\ V_y \end{bmatrix} + \begin{bmatrix} 0_2 \\ \sqrt{q} I_2 \end{bmatrix} \dot{w}(t) \quad (6.49)$$

离散的两维观测方程为

$$z = \begin{bmatrix} I_2 & 0_2 \end{bmatrix} \begin{bmatrix} x \\ y \\ V_x \\ V_y \end{bmatrix} \quad (6.50)$$

初始状态误差方差为

$$\bar{V}_0 = \text{cov} \left\{ \begin{bmatrix} \mathbf{x} \\ \mathbf{y} \\ \mathbf{V}_x \\ \mathbf{V}_y \end{bmatrix} \begin{bmatrix} \mathbf{x} & \mathbf{y} & \mathbf{V}_x & \mathbf{V}_y \end{bmatrix} \right\} = \begin{bmatrix} \sigma_p^2 \mathbf{I}_2 & \mathbf{0}_2 \\ \mathbf{0}_2 & \sigma_v^2 \mathbf{I}_2 \end{bmatrix} \quad (6.51)$$

其中  $\mathbf{0}_2$  和  $\mathbf{I}_2$  分别为二维零矩阵和二维单位矩阵,  $\sigma_x^2 = \sigma_y^2 = \sigma_p^2$ 、 $\sigma_{V_x}^2 = \sigma_{V_y}^2 = \sigma_v^2$  分别为初始位置方差和初始速度方差。

该 O—U 模型将一个真实目标的机动行为近似表示为速度随机变化 (如目标随机转弯或随机变速),  $\beta$  为目标机动频率,  $\beta^{-1}$  表示两次机动之间的平均时间或每次连续常速运动的平均时间<sup>[60, 61]</sup>。为简单起见, 我们采用同步、均匀测量, 即  $t_{i(k+1)} - t_{ik} \equiv \Delta T$  ( $k=1, \dots, N$ ,  $t_0 = t_{i1}$ ), 并且融合时刻与测量时刻相同 (不考虑传输延迟), 即  $t_F = t_{iN}$  ( $i=1, 2$ )。

通常, 仿真模型中的目标机动采用常速模型加小白噪声 (幅度较小、密度  $q$  在一定范围变化的白噪声) 模型来近似, 即  $\beta = 0$ ; 当目标状态超出预测状态的小白噪声幅度时, 即认为出现了机动<sup>[64, 65]</sup>。我们针对这里选用的上述 O—U 模型, 对其中参数  $\beta$ 、 $q$  的含义及其与目标状态之间的关系说明如下:

时间常数  $\beta^{-1}$  和白噪声密度  $q$  是影响目标运动状态 (使目标运动速度出现变化) 的两个主要参数。如果目标速度由微分方程 (6.49) 给出, 速度变化  $dV(t) = -\beta V(t)dt + \sqrt{q}dw(t)$  是一个先验稳态过程, 并带有平稳的协方差矩阵  $\sigma_v^2 \mathbf{I}_2$ , 则参数  $q$  与  $\beta$  具有关系:  $q = 2\beta\sigma_v^2$ 。我们在这里之所以采用带有标准偏差  $\sigma_v$  的平稳随机过程表示目标速度, 是为了用白噪声密度来控制速度不确定性和无限增长, 以充分反映实际运动对象的物理状态, 特别是地面、水面、水下目标的运动状态, 这就能够克服模型与现实目标状态变化之间的矛盾, 这是 O—U 模型的典型特征, 也是我们采用该模型的主要动因。这样一来, 基于 O—U 模型产生的剧情就能够对多种目标态势下的一次航迹融合各项准则的融合性能进行比较和评估。

图 6.5 给出了 O—U 模型的主要特征, 其中图 6.5 (a) 表示融合时刻目标先验位置的均方根误差 (RMS) 相对初始位置 RMS 随时间的相对增长状况, 其随着速度不确定性  $\sigma_v$  产生的  $\beta^{-1}(1 - e^{-\beta t})\sigma_v$  (当  $\beta$  很小时, 近似为  $\sigma_v t$ ; 当  $\beta$  很大时, 接近于 0) 以及白噪声密度的增长而增长 (当  $\beta$  很小时, 近似为  $\sqrt{(2/3)\beta\sigma_v^2 t^3}$ ; 当  $\beta$  很大时, 近似为  $\sigma_v \sqrt{2\beta^{-1}t}$ )。在 O—U 模型中, 作为时间函数的融合时刻先验位置误差的增长通常慢于传统常速运动的小白噪声模型。

从图 6.5 (b) 中可以看出在一个固定的航迹融合周期  $\Delta T$  内以初始位置 RMS 归一化的融合时刻先验位置的 RMS 随归一化白噪声密度  $q/(\sigma_v^2/\Delta T)$  的变化情况。由于  $q = 2\beta\sigma_v^2$ , 随着  $q \downarrow 0$ , 出现  $\beta \downarrow 0$ , 此时该模型接近一个确定性系统; 而随着归一化白噪声密度的增长  $q \uparrow \infty$ , 也出现  $\beta \uparrow \infty$ , 此时融合时刻先验位置的不确定性趋于稳定。这是由于随着  $\beta \uparrow \infty$  (从而  $q \uparrow \infty$ ), 目标状态相邻机动之间的平均时间接近于零, 最终得到在各个方向都可能出现机动的一个点, 使各方向的可能机动相互抵消。

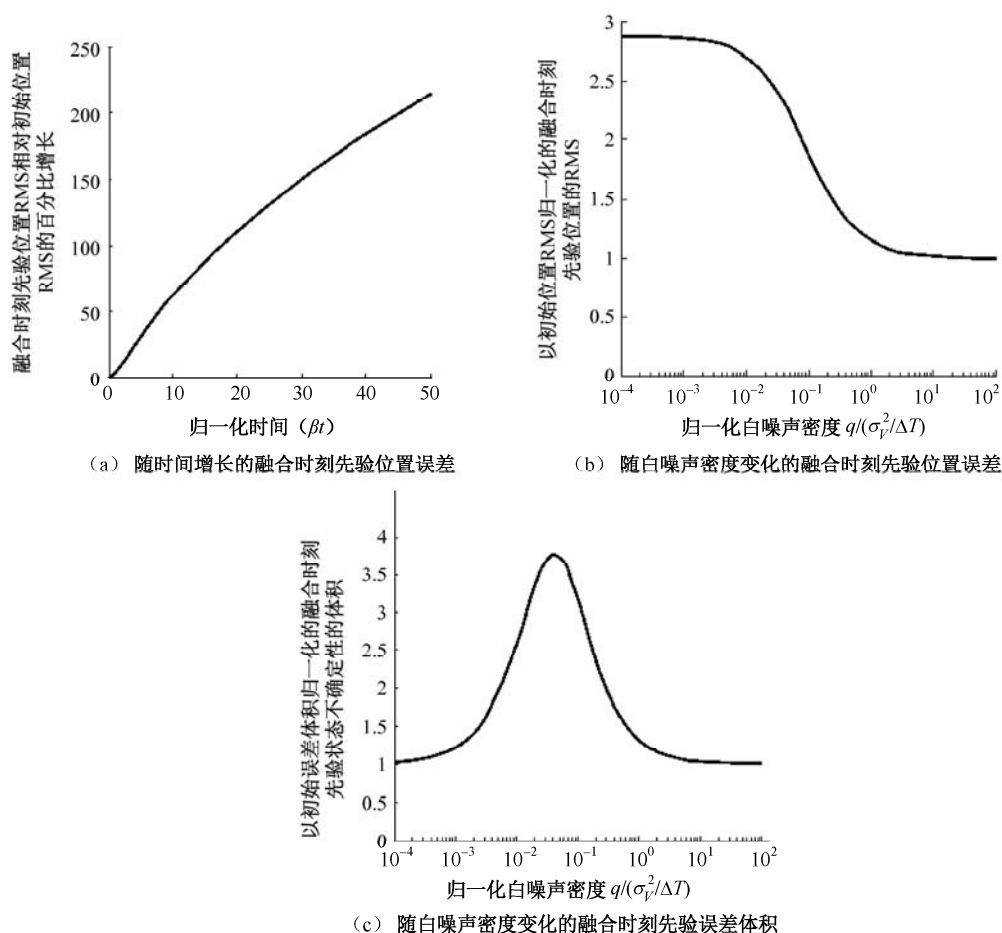


图 6.5 Ornstein—Uhlenbeck 模型主要特征

图 6.5 (c) 给出了在固定融合周期  $\Delta T$  内先验状态不确定性的体积（用初始状态不确定超体积归一化）随归一化白噪声密度  $q/(\sigma_v^2/\Delta T)$  的变化情况。值得注意的是，从图 6.5 (c) 中看到，随着  $q$  值的变小和增大（对应的  $\beta$  也随之变小和增大），融合时刻先验状态，即目标位置—速度的联合不确定性超体积趋于与初始状态的不确定性超体积具有相同尺寸，该超体积的极大值在归一化白噪声密度的中间值附近达到。对于较小的  $\beta$ ，位置—速度的交叉协方差使目标先验状态不确定性体积成为位置和时间的不变量（其仅依赖与速度变化）；而对于较大的  $\beta$ ，该位置—速度的交叉协方差消失，此时目标状态协方差矩阵趋于稳定。

下面针对追加同性能传感器和互补异性能传感器等两种传感器的配置状况，给出基于 O—U 模型的各航迹融合准则性能的比较案例。

### 6.4.2 追加传感器情况仿真案例

追加传感器的概念是几乎具有相同性能特征的两个传感器同时跟踪目标，其中第二个传感器是由于第一个传感器跟踪性能不足而追加的，以满足目标跟踪应用需求。在仿真实验中，我们假设每个传感器在累积 10 个测量之后，生成局部航迹，然后传递给全局站点进行航迹

融合。这里，两独立传感器测量的协方差矩阵均为  $\mathbf{R}_{ik} = \begin{bmatrix} \sigma_m^2 & 0 \\ 0 & \sigma_m^2 \end{bmatrix} (k=1, \dots, 10; i=1, 2)$ ，于是  $\mathbf{V}_1 = \mathbf{V}_2 = \sigma_m^2$ 。

在这种特定情况下，交叉协方差（CC）融合准则简化为  $\mathbf{w}_1 = \mathbf{w}_2 = \frac{1}{2} \mathbf{I}$ ，即凸组合融合（自然融合，NF）准则。此时，两局部航迹估计误差的交叉协方差的大小并不影响传感器测量之间的交叉协方差和融合准则之间的独立性。

此外，由于  $\mathbf{V}_1 = \mathbf{V}_2$ ，对于任何标量权值  $\alpha \in [0, 1]$ ，任一协方差交集（CI）融合准则都能得到相同的融合协方差  $\hat{\mathbf{V}}_F$ 。尽管实际的融合估计误差协方差可能随权值  $\alpha$  而改变，但考虑对称性，我们仍有理由选择  $\alpha = 1/2$ ，这将导致 CI 融合准则（无论是最小熵（Shannon）准则还是均方差最小化（Chen—Arambel—Mehra）融合准则）与交叉协方差/凸组合融合准则相同。然而，如所周知，由任一 CI 融合准则进行融合产生的融合误差协方差都与每个局部估计误差协方差相同，即都是不真实（过于不利）的。

图 6.6 给出了归一化白噪声密度  $q/(\sigma_v^2/\Delta T)$  在一个较大变化范围（ $10^{-4} \sim 10^4$  dB）的情况下，4 个航迹融合准则的估计性能（即航迹位置估计误差 RMS 和航迹速度估计误差 RMS）与集中式跟踪性能的仿真比较图示。这 4 个融合准则分别是交叉协方差（CC）融合准则（同时表示凸组合融合准则和协方差交集 CI 融合准则）、极小方差（MV）融合准则、小航迹（TL）融合准则和贝叶斯极大似然（BML）融合准则。剧情模型中的其他关键参数为：初始位置标准偏差  $\sigma_p = 10\sigma_m$ ，平稳速度标准偏差  $\sigma_v = 3(\sigma_m/\Delta T)$ 。在图 6.6 中，横轴表示归一化白噪声密度  $q/(\sigma_v^2/\Delta T)$ ，纵轴表示位置估计误差 RMS（图 6.6（a））和速度估计误差 RMS（图 6.6（b））相对于集中式跟踪相应误差 RMS 的百分比增量（显然这里的纵轴零点线表示集中式跟踪误差 RMS 随归一化白噪声的增长情况）。

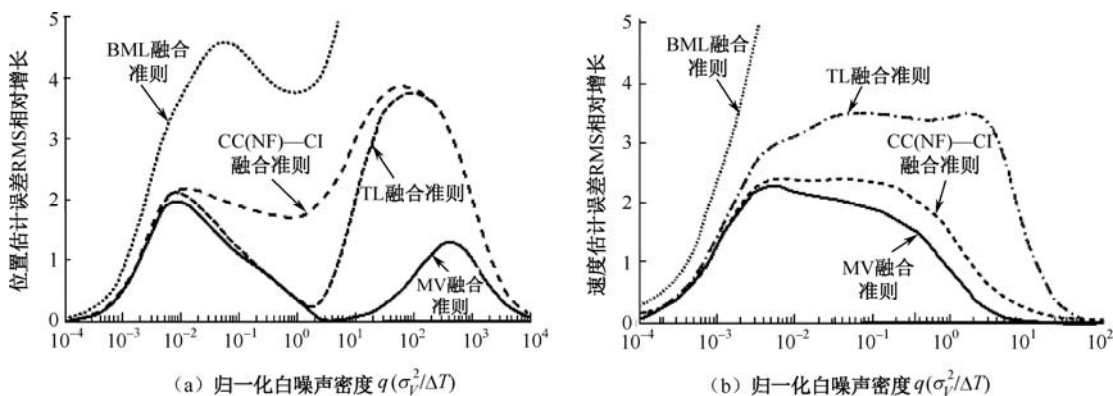


图 6.6 随归一化过程噪声密度变化的各航迹融合准则状态估计误差 RMS 相对于集中式跟踪误差 RMS 增长的百分比

从图 6.6 可以得出以下几点结论：

- 在一个较大范围变化的过程噪声之下，随过程噪声增加，集中式跟踪的状态（位置和速度）估计退化要比 CC（NF）—CI 融合准则、MV 融合准则、TL 融合准则的航迹

融合跟踪性能退化少 4%。这与文献[3, 50]提供的观察报告一致。

- 使用严格贝叶斯意义下的极大似然 (BML) 融合准则, 如图 6.6 (a)、(b) 所示的 BML 融合准则的估计性能出现了明显较差的情况。在过程噪声密度较小即  $q < \sigma_v^2 / \Delta T$  的情况下, 仿真结果统计表明, BML 融合准则的性能比集中式跟踪位置估计误差 RMS 相对增长 10%~30%; 当  $q > \sigma_v^2 / \Delta T$  时, BML 融合准则的估计性能, 特别是速度估计性能迅速退化, 估计误差迅速增长。图 6.6 中未给出 BML 融合准则性能的全部范围, 因其劣质性能会掩盖与其他三个融合准则性能的比较。
- 由 6.3.2 节 BML 准则的定义可知, BML 航迹融合准则是采用严格贝叶斯意义下定义的似然函数, 即将两局部估计  $\hat{\mathbf{x}}_1$ 、 $\hat{\mathbf{x}}_2$  作为全局融合输入测量向量, 通过使其基于目标状态  $\mathbf{x}$  的条件概率密度 (似然函数) 极大化, 获得状态  $\mathbf{x}$  的最优估计。注意式 (6.29) 和式 (6.30), 为了使 BML 准则的性能接近极小方差 (MV) 融合准则下的最优, 必须使下式成立:  $\bar{\mathbf{V}} \approx \mathbf{V}_{xz} (\mathbf{V}_{zz} - \mathbf{V}_{zx} \mathbf{V}^{-1} \mathbf{V}_{xz})^{-1} \mathbf{V}_{zx}$ , 这在过大的过程噪声密度下显然是不适用的。此外, 从 6.3.2 节可以看出, 交叉协方差 (CC) 融合准则使用经典统计意义下的似然函数, 实际上是使两局部估计  $\hat{\mathbf{x}}_1$ 、 $\hat{\mathbf{x}}_2$  与全局估计  $\hat{\mathbf{x}}_F$  之差的联合概率密度达极大, 其性能显然要比采用严格贝叶斯意义下的似然函数的 BML 融合准则的性能要好得多。
- 极小方差 (MV) 航迹融合准则由于既考虑了消除共用过程噪声引起的隐式相关性, 又考虑了消除共用先验信息引起的显式相关性, 因此在图 6.6 中比其他三个航迹融合准则具有更好的最优状态估计性能。
- 没有使用传感器之间交叉协方差的小航迹 (TL) 融合规则在图 6.6 (a) 所示的目标位置融合估计性能中表现出比使用交叉协方差的融合准则 (CC (NF) —CI 融合准则) 更好的性能; 但对于目标速度估计则正相反, CC (NF) —CI 融合准则的性能要优于 TL 融合准则。后面关于互补传感器情况和目标连续跟踪态势下的反复航迹融合情况, 这个规律通常也是正确的。
- 除 BML 融合准则外, 所有其他三个航迹融合准则当  $q \downarrow 0$  或  $q \uparrow \infty$  时, 其性能都收敛到集中跟踪融合性能, 只是 CC (NF) —CI 融合准则由于未使用目标先验状态信息, 当  $q \downarrow 0$  时, 会出现一个小的偏差。这就在一定程度上印证了 Koch—Govaers 融合准则所指出的, 在一定条件下分布式航迹融合通过对局部航迹估计的重构能够产生类似于集中式测量融合的最优性能。

图 6.7 给出了追加传感器的情况下, 改变目标初始位置标准偏差  $\sigma_p$  (表示先验信息改变) 所引起的 4 类航迹融合准则的融合目标位置估计和速度估计误差的 RMS 比集中式跟踪误差的 RMS 百分比增长情况的仿真结果。其中  $q = 0.1(\sigma_v^2 / \Delta T)$ ,  $\sigma_v = 3(\sigma_m / \Delta T)$ 。

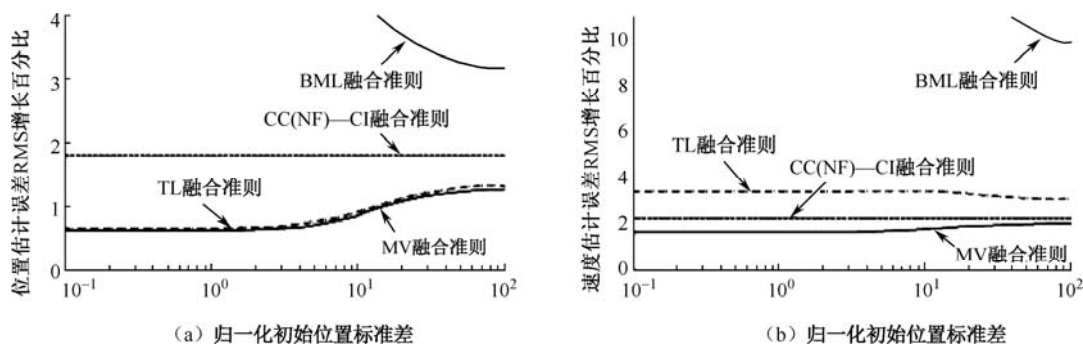


图 6.7 随  $\sigma_p$  变化的 4 类融合准则估计误差 RMS 比集中式跟踪误差 RMS 增长的百分比

从图 6.7 可以看出：

- CC (NF) —CI 融合准则由于不使用目标初始状态信息，因此其性能是  $\sigma_p$  的不变量。
- 与改变过程噪声密度获得的图 6.6 类似，在改变初始位置偏差  $\sigma_p$  的图 6.7 中，使用严格贝叶斯意义似然函数（或直接称为贝叶斯似然函数）的 BML 融合准则的状态估计性能明显比 CC (NF) —CI 融合准则的估计性能恶化得多。仿真结果统计表明，在初始状态不确定性  $\sigma_p$  较小的情况下，BML 融合准则下的目标速度估计误差比集中跟踪速度估计误差出现 20% 的增长（图 6.7 (b) 中没有画出该结论曲线）。
- 采用小航迹融合准则的目标位置估计性能始终优于 CC (NF) —CI 融合准则并接近 MV 融合准则的性能，与图 6.6 (b) 所示结果一样，图 6.7 (b) 也表明这个结论；对于目标速度估计要颠倒过来。
- 此外，进行改变稳态速度标准偏差  $\sigma_v$  的仿真结果表明， $\sigma_v$  的变化对任何航迹融合准则的性能几乎没有任何有效的影响。

### 6.4.3 互补传感器情况仿真案例

互补传感器在概念上指两个传感器的观测性能具有一定（较大）差异，二者在运行中通过性能互补，达到预期的目标探测与跟踪效果。

假设两个互补传感器的目标位置测量误差协方差矩阵分别为

$$\mathbf{R}_{1k} = \begin{bmatrix} \sigma_m^2 & 0 \\ 0 & 4\sigma_m^2 \end{bmatrix} \quad \mathbf{R}_{2k} = \begin{bmatrix} 4\sigma_m^2 & 0 \\ 0 & \sigma_m^2 \end{bmatrix} \quad k=1, \dots, N$$

这两个协方差矩阵表示两传感器在观测方向上具有  $90^\circ$  的差异，如它们分别瞄准  $x$  方向和  $y$  方向。仿真实验中仍采用 6.4.1 节给出的 O—U 模型和相同的参数。

图 6.8 给出了基于两互补传感器的几种航迹融合准则的估计性能（指相对于集中式跟踪相应误差增长）随归一化过程噪声密度变化的情况。其中，每个局部测量误差协方差矩阵  $\mathbf{R}_{1k}$  和  $\mathbf{R}_{2k}$  所体现的  $90^\circ$  观测方向差异被传播到各自的局部状态估计误差协方差矩阵之中，同时也传播到各融合准则的全局融合权重矩阵  $\mathbf{W}_1$  和  $\mathbf{W}_2$  之中。



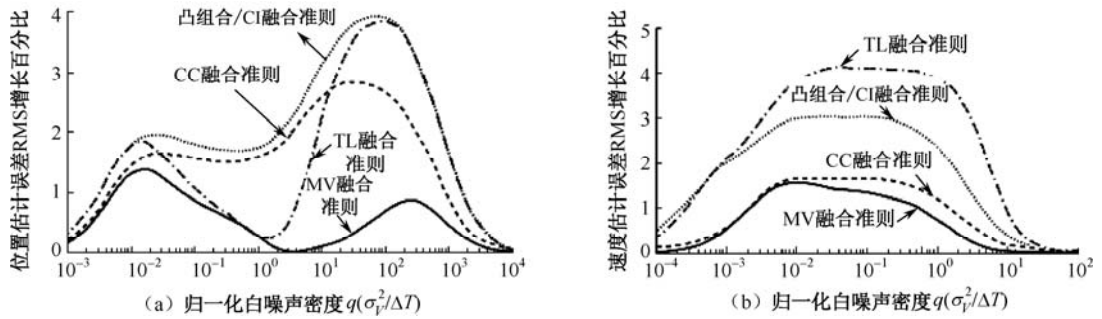


图 6.8 随归一化白噪声密度变化的几种融合准则状态估计误差 RMS 比集中式跟踪误差 RMS 增长的百分比

从图 6.8 可以得到以下几点结论：

- 图 6.8 所示的使用两传感器估计交叉协方差  $V_{12}$ （交叉协方差准则和极小方差准则）与不使用  $V_{12}$ （小航迹融合准则、凸组合与 CI 融合准则）的融合准则在性能上的差异表现在：①对于图 6.8 (a) 所示的位置估计误差 RMS 增长来说，当  $q$  值较小（接近于确定性状态）时，不使用  $V_{12}$  的小航迹（TL）融合规则展现出比交叉协方差（CC）融合准则更好的性能，并且存在低  $q$  峰值。当  $q$  值较大时，使用  $V_{12}$  的 CC 融合准则和 MV 融合准则展现了比不使用  $V_{12}$  的其他准则的明显优势，并且存在高  $q$  峰值。②对于图 6.8 (b) 所示的目标速度估计性能来说，使用  $V_{12}$  的 CC 融合准则和 MV 融合准则比不使用  $V_{12}$  的航迹融合准则具有明显优势，并且该优势相对于归一化过程噪声密度  $q$  是均匀的（不存在明显峰值）。
- 与 6.4.2 节追加传感器的情况（ $V_1 = V_2$ ）不同，互补传感器情况下  $V_1 \neq V_2$ ，因此协方差交集（CI）融合准则中的标量权值  $\alpha \in [0, 1]$  会改变融合估计误差协方差  $V_F$ ，这从式 (6.32) 即可得知。然而，对于我们的追加和互补案例，由于测量误差协方差矩阵  $R_{1k}$  和  $R_{2k}$  都是对角矩阵，因此，所有状态估计（自身和交叉）协方差矩阵也都是对角矩阵。这样，CI 融合准则的状态估计误差协方差矩阵  $V_F = [\alpha V_1^{-1} + (1-\alpha)V_2^{-1}]$  的行列式极小化与其迹极小化相同（在同一  $\hat{\alpha}$  处达到极小）或二者都简化为使  $\alpha(1-\alpha)$  达极大，并且都在  $\hat{\alpha} = 1/2$  处达到。这就使得所有的 CI 融合准则（最小熵融合准则或极小均方根误差准则）都恒等于凸组合（自然融合）准则，即  $V_F = [\alpha V_1^{-1} + (1-\alpha)V_2^{-1}]$ （ $i = 1, 2$ ）。

图 6.9 给出了 4 个航迹融合准则性能对目标初始位置估计精度即对该先验信息的敏感性（依赖性）。图 6.9 横轴为由目标位置测量标准偏差  $\sigma_m$  归一化的初始位置估计标准差，纵轴是融合位置误差（图 6.9 (a)）RMS 和融合速度误差（图 6.9 (b)）RMS 相比集中式跟踪误差 RMS 的百分比增长。与图 6.7 类似，这里的过程噪声密度和稳态速度误差协方差保持为常量  $q = 0.1(\sigma_v^2/\Delta T)$ ， $\sigma_v = 3(\sigma_m^2/\Delta T)$ 。




图 6.9 随归一化初始位置误差变化的几种融合准则状态估计误差 RMS 与集中跟踪误差 RMS 增长的百分比

从图 6.9 可得到下述几点结论：

- 由于 CC 融合准则和凸组合/CI 融合准则不使用先验信息，故如图 6.9 所示，初始位置误差的变化对它们的融合性能不产生影响。
- 由于两传感器可观测性的差异，其交叉相关产生的融合误差增长显而易见，如图 6.9 (a) 中的小航迹 (TL) 融合准则和 MV 融合准则产生的融合位置误差在初始位置误差标准差大于 5 之后，随两传感器测量交叉相关影响逐渐增大。图 6.9 (b) 中仅有 MV 融合准则产生的目标速度估计误差在初始位置标准差大于 2 之后，受测量交叉相关性影响而逐渐增大，趋于 CC 融合准则的融合性能。
- 与图 6.8 给出的结论相同，对于位置估计来说，TL 融合准则比 CC 融合准则性能更好，而对于目标速度估计来说，TL 融合准则的性能比 CC 融合准则差得多。

互补传感器关于各类融合准则的其他仿真结果几乎与追加传感器仿真结果（如图 6.7 所示）相同。由于与图 6.6 和图 6.7 的参数设置相同，并且仿真过程（改变敏感参数）以及过程噪声密度和初始位置精度的变化也与图 6.6 和图 6.7 相同。因此，除了贝叶斯极大似然 (BML) 融合准则外，其他几个准则性能的仿真结论也与图 6.6 和图 6.7 相同。这样一来，图 6.8 和图 6.9 同样展现了各不同航迹融合准则的健壮性（鲁棒性）。

## 6.5 目标连续跟踪中的反复航迹融合

我们在 6.3 节和 6.4 节中介绍了两传感器分布式目标定位（状态估计）中的一次航迹融合准则及其性能评估案例，本节将介绍目标跟踪过程中，局部站点（传感器）与全局融合中心之间通过通信传输不断进行信息交换，反复进行航迹融合，以实现目标连续跟踪的分布式航迹融合结构、准则和仿真案例。

### 6.5.1 反复航迹融合结构与分类

从图 6.2 展示的对目标航迹的一次和反复融合的概念不难看出，一次航迹融合只是反复航迹融合中的一个环节，或者说是目标连续跟踪中一个航迹点状态的融合估计，旨在实现目标航迹的连续延伸。然而，由于反复航迹融合涉及一次航迹融合的目标状态估计信息的不断交换，并且通过传感器与融合中心之间的反复通信（通过网络）予以实现，因此，反复航迹

融合不是各个一次航迹融合信息和功能的简单连接，它具有不同的连接结构和信息关系。

为简单起见，我们采用两个传感器分布式跟踪系统的三种主要结构来描述反复航迹融合的信息关系、功能和准则及仿真案例。两传感器分布式跟踪系统的三种连接结构如图 6.10 所示。

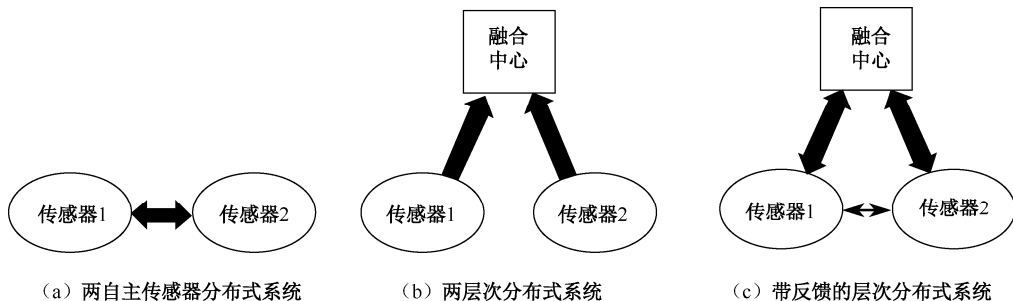


图 6.10 两传感器分布式跟踪系统的三种连接结构

图 6.10 中，我们假设每个传感器自身具有独立目标的探测、数据处理与目标跟踪能力，两个自主传感器能够作为完全自主的系统独立运行，它们之间交换数据，并将处理的数据交替（有选择地）向上一级系统（称为融合中心或融合站点）报告。融合中心可以将融合的（全局的）目标状态估计（根据需要）反馈给两个局部传感器系统，以改善各局部系统的性能，提升其目标跟踪能力。本节我们首先考虑不带反馈的情况，然后考虑带反馈的情况。

我们假设 6.2.1 节描述的具有线性观测模式的两个传感器所跟踪的同一目标具有线性运动状态模型（6.3）。为简单计，仅考虑两传感器在同一时刻与融合中心交换信息，并在  $t_{F_1}, t_{F_2}, \dots (t_0 < t_{F_1} < t_{F_2} < \dots)$  等时刻反复进行信息交换，如图 6.2 (b) 所示。在图 6.2 (b) 中，两个传感器的局部状态及估计误差协方差矩阵分别表示为： $t_{F_1}$  时刻为  $[(\hat{x}_{11}, V_{11}), (\hat{x}_{12}, V_{12})]$ ， $t_{F_2}$  时刻为  $[(\hat{x}_{21}, V_{21}), (\hat{x}_{22}, V_{22})]$ ， $t_{F_3}$  时刻为  $[(\hat{x}_{31}, V_{31}), (\hat{x}_{32}, V_{32})]$  等，这里将每个时刻  $t_{F_k}$  的融合状态估计表示为  $\hat{x}_{F_k}$  ( $k=1, 2, \dots$ )。

对于带有和不带有反馈的层次结构反复融合情况，融合变换皆可表示为  $\hat{x}_{F_k} = \Phi_k(\hat{x}_{11}, \hat{x}_{12}; \hat{x}_{21}, \hat{x}_{22}; \dots; \hat{x}_{k1}, \hat{x}_{k2})$ （这里  $\Phi_k$  是我们采用的线性高斯状态模型产生的离散线性变换函数或仿射函数），基于其所采用的融合输入信息的时间特征，可进行下述分类：

① 无记忆：即  $\hat{x}_{F_k} = \Phi_k(\hat{x}_{k1}, \hat{x}_{k2})$ ，全局融合即仅使用最近时间的两个传感器局部估计结果；

② 有限记忆：即  $\hat{x}_{F_k} = \Phi_k(\hat{x}_{(k-l+1)1}, \hat{x}_{(k-l+1)2}; \dots; \hat{x}_{k1}, \hat{x}_{k2})$ ，全局融合即仅使用两传感器最近时间  $l$  对局部的估计结果；

③ 全记忆：即  $\hat{x}_{F_k} = \Phi_k(\hat{x}_{11}, \hat{x}_{12}; \hat{x}_{21}, \hat{x}_{22}; \dots; \hat{x}_{k1}, \hat{x}_{k2})$ ，全局融合采用两传感器已经接收到的所有局部估计。

显然，我们可以把 Bar Shalom—Campo 的交叉协方差准则和凸组合/自然融合准则归为无记忆准则类，因为它们不使用共用先验信息  $(\bar{x}, \bar{V})$ ，仅使用两个传感器刚刚报来的一对局部航迹状态估计结果；而 MV 融合准则和 BML 融合准则可以归为有限记忆准则类或全记

忆准则类,因为它们使用共用先验信息( $\bar{x}, \bar{V}$ )。先验信息可根据需要基于有限记忆(当目标出现机动时)或全记忆生成(当目标始终处于平稳状态)。至于小航迹融合准则可能变成无记忆准则(当小航迹仅是一个测量点)或单步有限记忆准则(指一个融合步骤中传感器局部估计采用的有限个测量)。

## 6.5.2 不带反馈的反复航迹融合

### 1. 融合结构

在不带反馈的层次融合结构中,首先考虑每个传感器系统仅使用自身探测获得的局部测量数据,不与其他传感器测量数据混合使用,而融合站点的全局状态估计则通过对各非混合局部估计的组合实现。考虑的第二点是不允许传感器系统的局部航迹融合使用其他融合信息(包括自身节点前面时刻的融合信息,其他传感器站点或全局融合站点的融合信息),因为无论采用什么融合准则或全局与其他站点向该局部传感器系统怎样传送其融合结果,都会由于所使用的其他融合信息中所含有的局部传感器测量数据而使被该传感器融合的局部数据受到污染(由可能产生的信息重复使用或相关性所致),导致局部系统的融合性能和最终的全局系统融合性能降低。考虑上述两点的反复航迹融合系统结构的数据处理可以通过如图 6.11 所示的两层次系统或两个自主系统实现。

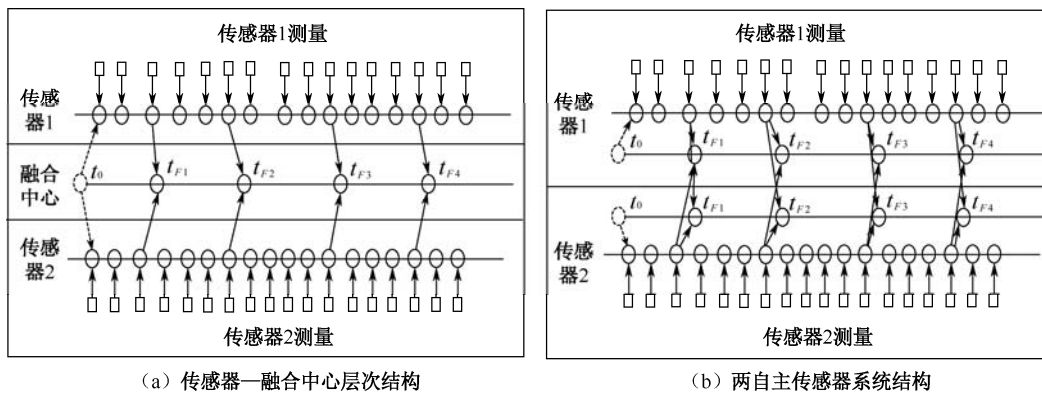


图 6.11 不带反馈的两传感器航迹融合结构信息图

图 6.11 给出了不带反馈的两传感器航迹融合结构信息图,这两个信息图在功能上是等价的,分别描述了两传感器——单融合中心系统和两自主传感器系统中的信息交换过程。图 6.11 中有向虚线和虚线圈表示先验信息(不同的航迹融合准则可使用,也可不使用),正方形表示传感器测量数据,将它们输入到信息图中的相应传感器节点并在其中累积起来。数据累积过程采用相同水平位置之间的水平连接信息流表示,图中没画出方向(从左向右)。图 6.11(a)给出了在融合中心实现的反复全局航迹融合信息图,融合中心在 $t_{F1}, t_{F2}, t_{F3}, t_{F4}, \dots$ 时间点上融合两传感器报知的局部航迹估计,它们分别是基于各自上次通信以来所累积的一段测量生成的。图 6.11(b)没有设置融合中心站点,但每个局部传感器系统设置两个航迹状态滤波器,一个是局部航迹估计器,一个是全局航迹估计器。每个传感器在 $t_{F1}, t_{F2}, t_{F3}, t_{F4}, \dots$

时间点经局部滤波器基于相应时段内自身累积测量产生局部航迹估计,并将该局部估计结果传送给自身全局滤波器和另一传感器的全局滤波器,全局滤波器对自身和接收的另一传感器的局部估计进行融合产生全局航迹估计结果。图 6.11 (b) 所示结构又被称为基于局部估计的全分布航迹融合结构,在该结构中,每个传感器的全局滤波器能够获得同样的各传感器局部估计输入,因此能够产生完全相同的全局航迹估计结果。其中的全局滤波器有时又被称为隐蔽跟踪器 (Shadow tracker) [27]。值得注意的是,图 6.11 (b) 所示的全分布结构需要具有全速率的通信带宽,以实现各传感器局部航迹估计的实时 (无延误) 送达。美海军海上编队防空作战应用的协同作战能力 (Cooperative Engagement Capability, CEC) 系统 [66] 就采用该分布式结构,实现对空中目标的多舰协同打击。其中各舰之间实时传输火控传感器数据的数据分发系统 (Data Distribution System, DDS) 的传输速率达 48 Mbit/s。

## 2. 融合准则

第 6.3.2 节中引入的各一次航迹融合准则在目标连续跟踪中的反复航迹融合情况可以改写如下:

① 交叉协方差 (CC) 融合准则, 凸组合 (NF) 与 CI 融合准则。

这几个航迹融合准则不使用先验信息,对于反复航迹融合来说,在融合时刻  $t_{F_k}$  的先验信息可以视为基于前一融合时刻  $t_{F_{(k-1)}}$  之前累积信息产生的  $t_{F_k}$  时刻全局估计预测,而这几个融合准则忽略了该先验信息,只简单地组合最近得到的每个传感器的局部状态估计,故可视为无记忆融合准则。

② 极小方差 (MV) 融合准则。

在图 6.11 中,无论是图 6.11 (a) 的融合中心还是图 6.11 (b) 的一个局部传感器系统设置的全局融合滤波器,采用极小方差融合准则进行航迹融合时,在融合时刻  $t_{F_k}$  除采用当前一对局部估计  $[(\hat{\mathbf{x}}_{k1}, \mathbf{V}_{k1}), (\hat{\mathbf{x}}_{k2}, \mathbf{V}_{k2})]$  之外,还采用累积的多对局部航迹估计  $[(\hat{\mathbf{x}}_{11}, \mathbf{V}_{11}), (\hat{\mathbf{x}}_{12}, \mathbf{V}_{12}), \dots, (\hat{\mathbf{x}}_{(k-1)1}, \mathbf{V}_{(k-1)1}), (\hat{\mathbf{x}}_{(k-1)2}, \mathbf{V}_{(k-1)2})]$ 。这样, MV 融合准则下的目标航迹状态  $\mathbf{x}(t_F)$  的线性估计  $\hat{\mathbf{x}}_{Fk}$  是所有记忆的有效估计  $[(\hat{\mathbf{x}}_{ji}, \mathbf{V}_{ji})_{i=1}^2]_{j=1}^k$  和一个先验信息  $P[\mathbf{x}(t_0)]$  (其等价于带有均值  $\bar{\mathbf{x}}_k$  和协方差  $\bar{\mathbf{V}}_k$  的概率密度的线性函数)。在 6.3.2 节给出的一次航迹融合的极小方差融合准则中,若设置作为全局融合输入的各局部航迹估计的增广向量  $\mathbf{Z} = [(\hat{\mathbf{x}}_{ji}, \mathbf{V}_{ji})_{i=1}^2]_{j=1}^k$ , 并设  $\mathbf{x} = \mathbf{x}(t_F)$ , 通过计算该增广向量及其与目标航迹状态  $\mathbf{x}$  的协方差矩阵  $\mathbf{V}_{ZZ}$  和  $\mathbf{V}_{xZ}$ , 则 MV 融合准则可以表示为

$$\begin{cases} \hat{\mathbf{x}}_{Fk} = \mathbf{w}_{k0} \bar{\mathbf{x}}_k + \sum_{j=1}^k \sum_{i=1}^2 \mathbf{w}_{ji} \hat{\mathbf{x}}_{ji} \\ \mathbf{w}_{k0} + \sum_{j=1}^k \sum_{i=1}^2 \mathbf{w}_{ji} = \mathbf{I} \end{cases} \quad (6.52)$$

显然这是一个全记忆航迹融合准则,并且是目标全航迹的最优线性无偏估计 (BLUE)。值得注意的是,这里矩阵  $\mathbf{V}_{ZZ}$  和  $\mathbf{V}_{xZ}$  的计算举足轻重,由于其含有多周期局部状态估计随机

向量 $[(\hat{\mathbf{x}}_{ji})_{i=1}^2]_{j=1}^k$ ，故存在较大难度。然而，可以通过采取对 6.3.2 节式 (6.26) 和式 (6.27) 的导出方法进行简单（逐一）扩展来实现。

### ③ 融合准则 $MV_1$ 和 $MV_2$ 。

我们已注意到，文献[31]将  $MV$  航迹融合准则称为准小航迹融合方法。这是因为若在式 (6.52) 中用  $\sum_{j=k-l+1}^k$  代替  $\sum_{j=1}^k$ ，我们就可以得到一个有限记忆 ( $l > 1$ ) 或无记忆 ( $l = 1$ ) 的航迹融合准则，这相当于用  $l$  来调节“小航迹”的长度，分别称为  $MV_2$  准则和  $MV_1$  准则。此时，采用该“准小航迹”的  $MV$  融合准则就是基于权值系数 ( $\mathbf{w}_{k0}; \mathbf{w}_{k1}, \mathbf{w}_{k2}, \dots; \mathbf{w}_{(k-l+1)1}, \mathbf{w}_{(k-l+1)2}$ ) 的有限记忆 ( $l$  个最近位置点) 目标航迹的最优线性无偏估计 (BLUE)，其约束条件是  $\mathbf{w}_{k0} + \sum_{j=k-l+1}^k \sum_{i=1}^2 \mathbf{w}_{ji} = \mathbf{I}$ 。显然，Bar Shalom—Campo 的交叉协方差融合准则仅是对 ( $\mathbf{w}_{k1}, \mathbf{w}_{k2}$ ) ( $\mathbf{w}_{k1} + \mathbf{w}_{k2} = \mathbf{I}, \mathbf{w}_{ji} = 0, j \neq k$ ) 的最优线性无偏估计。

### ④ 贝叶斯极大似然 (BML) 航迹融合准则。

6.3.2 节给出了一次融合中使用严格贝叶斯意义下的似然函数的贝叶斯极大似然 (BML) 航迹融合准则的定义式 (6.31)，其中使用了先验信息  $\bar{\mathbf{x}}, \bar{\mathbf{V}}$ 。在这里能够以与上述  $MV$  融合准则完全相同的方式将先验信息  $\bar{\mathbf{x}}, \bar{\mathbf{V}}$  扩展到无反馈反复航迹融合准则的全记忆、有限记忆甚至是无记忆 (不采用先验信息) 情况中。然而，由于如 6.4.2 节追加传感器和 6.4.3 互补传感器仿真案例所示，BML 融合准则的一次航迹融合性能不佳，故我们在本章余下部分将不讨论 BML 融合准则，因为可以预期其对目标连续跟踪的反复航迹融合来说性能也是不佳的。

### ⑤ 小航迹 (TL) 融合准则及其解相关方法。

6.3.2 节定义的小航迹融合准则式 (6.20) 可以通过取

$$\begin{cases} \mathbf{w}_{k0} = -\mathbf{V}_{F_k} \bar{\mathbf{V}}_k^{-1} \\ \mathbf{w}_{ki} = -\mathbf{V}_{F_k} \bar{\mathbf{V}}_{ki}^{-1} \end{cases} \quad i=1,2 \quad k=1,2,\dots \quad (6.53)$$

将一次航迹融合的小航迹准则扩展到目标连续跟踪的反复航迹融合情况。我们注意到 6.3.2 节给出的一次小航迹融合准则通过将式 (6.21) 分解为式 (6.23) 和式 (6.24)，解除了由共用先验信息 ( $\bar{\mathbf{x}}, \bar{\mathbf{V}}$ ) 引起的两局部航迹估计  $\hat{\mathbf{x}}_1$  和  $\hat{\mathbf{x}}_2$  之间的相关性。我们可以把一次小航迹融合准则的这一解相关功能直接应用于反复航迹融合中求解最近的两个局部估计  $[(\hat{\mathbf{x}}_{k1}, \mathbf{V}_{k1}), (\hat{\mathbf{x}}_{k2}, \mathbf{V}_{k2})]$  与共用先验估计 ( $\bar{\mathbf{x}}_k, \bar{\mathbf{V}}_k$ ) 之间的相关性。即将式 (6.24) 改写为

$$\begin{cases} \tilde{\mathbf{V}}_{ki}^{-1} \mathbf{z}_{ki} = \mathbf{V}_{ki}^{-1} \hat{\mathbf{x}}_{ki} - \bar{\mathbf{V}}_k^{-1} \bar{\mathbf{x}}_k \\ \tilde{\mathbf{V}}_{ki}^{-1} = \mathbf{V}_{ki}^{-1} - \bar{\mathbf{V}}_k^{-1} \end{cases} \quad i=1,2 \quad (6.54)$$

这里 ( $\bar{\mathbf{x}}_k, \bar{\mathbf{V}}_k$ ) 是基于  $t_{F(k-1)}$  时刻及之前的两个传感器测量融合生成的  $t_{F_k}$  时刻航迹状态的估计预测，用作  $t_k$  时刻全局融合的共用先验信息。

对于融合中心向局部站点无反馈的层次结构，能够证明<sup>[22]</sup>对于无过程噪声的确定性目标动态以及融合速率与传感器目标再现率相同的非确定性目标动态，这种解除相关的反复航迹融合准则能够达到集中式目标跟踪性能。

如果全局融合时不采用全局共用先验信息  $(\bar{\mathbf{x}}_k, \bar{\mathbf{V}}_k)$ ，而是采用每条局部航迹的预测估计  $(\mathbf{x}_{k_i}, \mathbf{V}_{k_i})_{i=1}^2$  信息（局部共用先验信息），则在全局融合中要去除两局部估计与相应局部先验信息之间的相关性，公式为

$$\begin{cases} \tilde{\mathbf{V}}_{k_i}^{-1} \mathbf{z}_{k_i} = \mathbf{V}_{k_i}^{-1} \hat{\mathbf{x}}_{k_i} - \bar{\mathbf{V}}_{k_i}^{-1} \bar{\mathbf{x}}_{k_i} \\ \tilde{\mathbf{V}}_{k_i}^{-1} = -\mathbf{V}_{k_i}^{-1} - \bar{\mathbf{V}}_{k_i}^{-1} \end{cases} \quad i=1,2 \quad (6.55)$$

这就使每个传感器得到解除自身局部相关的一对  $(\mathbf{z}_{k_i}, \tilde{\mathbf{V}}_{k_i})_{i=1,2}$ ，该公式与方程（6.54）类似<sup>[16]</sup>。

与 6.3.2 节所述相同，式（6.54）和式（6.55）中用于解除相关的中间变量  $\mathbf{z}_{k_i}$ （ $i=1,2$ ）被称为伪测量或等效测量，它被用来代替基于两个序贯的融合时刻  $t_{F_{(k-1)}}$  与  $t_{F_k}$  之间累积的测量产生的局部估计  $(\hat{\mathbf{x}}_{k_i}, \tilde{\mathbf{V}}_{k_i})_{i=1,2}$ 。通常将  $t_{F_{(k-1)}}$  与  $t_{F_k}$  之间累积的测量集合称为目标在该时间段的一条小航迹。对解除相关的一对  $(\mathbf{z}_{k_i}, \tilde{\mathbf{V}}_{k_i})_{i=1,2}$ ，可以采用任何集中式融合状态更新方程得到目标航迹的全局估计：

$$\begin{cases} \mathbf{V}_{F_k}^{-1} \mathbf{x}_{F_k} = \bar{\mathbf{V}}_{F_k}^{-1} \bar{\mathbf{x}}_{F_k} + \tilde{\mathbf{V}}_{k_1}^{-1} \mathbf{z}_{k_1} + \tilde{\mathbf{V}}_{k_2}^{-1} \mathbf{z}_{k_2} \\ \mathbf{V}_{F_k}^{-1} = \bar{\mathbf{V}}_{F_k}^{-1} + \tilde{\mathbf{V}}_{k_1}^{-1} + \tilde{\mathbf{V}}_{k_2}^{-1} \end{cases} \quad (6.56)$$

式（6.56）是基于解相关式（6.54）实现的，类似于一次融合小航迹准则中的式（6.23）。若采用解相关式（6.55），则目标航迹全局估计的更新方程为

$$\begin{cases} \mathbf{V}_{F_k}^{-1} \hat{\mathbf{x}}_{F_k} = \bar{\mathbf{V}}_{k_1}^{-1} \bar{\mathbf{x}}_{k_1} + \bar{\mathbf{V}}_{k_2}^{-1} \bar{\mathbf{x}}_{k_2} + \tilde{\mathbf{V}}_{k_1}^{-1} \mathbf{z}_{k_1} + \tilde{\mathbf{V}}_{k_2}^{-1} \mathbf{z}_{k_2} \\ \mathbf{V}_{F_k}^{-1} = \bar{\mathbf{V}}_{k_1}^{-1} + \bar{\mathbf{V}}_{k_2}^{-1} + \tilde{\mathbf{V}}_{k_1}^{-1} + \tilde{\mathbf{V}}_{k_2}^{-1} \end{cases} \quad (6.57)$$

式（6.54）～式（6.57）中的全局预测  $(\bar{\mathbf{x}}_{F_k}, \bar{\mathbf{V}}_{F_k})$  和局部预测  $(\bar{\mathbf{x}}_{k_i}, \bar{\mathbf{V}}_{k_i})_{i=1,2}$  可以通过对 6.3.1 节中式（6.9）和式（6.10）进行外推获得。

小航迹融合预测尽管使用了外推到  $t_F$  时刻的全局状态估计或局部状态估计作为全局融合先验信息，仍可以视为无记忆准则，因其仅使用最近时刻  $t_F$  的一对局部估计  $(\hat{\mathbf{x}}_{k_1}, \hat{\mathbf{x}}_{k_2})$ 。同时，式（6.55）中用于解除相关使用  $t_{k-1}$  时刻局部估计  $(\hat{\mathbf{x}}_{(k-1)_1}, \hat{\mathbf{x}}_{(k-1)_2})$  对  $t_F$  时刻的外推值  $(\hat{\mathbf{x}}_{k_1}, \hat{\mathbf{x}}_{k_2})$ ，与式（6.55）中使用的  $t_{k-1}$  时刻全局估计  $\hat{\mathbf{x}}_{F_{(k-1)}}$  来产生  $t_k$  时刻的预测值  $\bar{\mathbf{x}}_{F_k}$  一样，皆可视为（一步）有限记忆融合准则。然而，容易证明，仅当目标运动状态是确定性的，即式（6.3）中  $\mathbf{B}(t) \equiv \mathbf{0}$  时，式（6.54）与式（6.55）所述的小航迹解相关公式才是等价的。当目标动态是非确定性时，二者将有所不同。如 6.3.2 节所述，这里给出的局部估计解相关小航迹滤波准则又被称为信道滤波<sup>[11]</sup>，因为用于全局融合的一对最近局部估计可以视为是由两个通信信道提供的。

### 3. 仿真案例

仿真案例剧情采用 6.4.1 节定义的 Ornstein—Uhlenbeck 模型，带有表示目标的随机变化的时间常数  $\beta$ （ $\beta^{-1}$  表示相邻两次机动之间的平均时间）和过程噪声密度  $q$ （它们之间具有关系： $q = 2\beta\sigma_v^2$ ）以及与预先的目标位置标准偏差  $\sigma_p$  和平稳速度标准偏差  $\sigma_v$ 。该仿真案

例仅针对两个互补传感器的情况,其目标位置测量协方差矩阵分别为  $\mathbf{R}_{1k} = \begin{bmatrix} \sigma_m^2 & 0 \\ 0 & 4\sigma_m^2 \end{bmatrix}$ ,

$\mathbf{R}_{2k} = \begin{bmatrix} 4\sigma_m^2 & 0 \\ 0 & \sigma_m^2 \end{bmatrix}$ ,其中  $\sigma_m$  为一次测量(标量  $x$  或  $y$ )随机误差标准差。如 6.4.2 节给出的,

在相邻两次全局航迹融合之间每个传感器积累 10 个同步测量产生局部航迹,反复进行 5 次(即 5 个全局融合周期)。采用 6.4.3 节一次航迹融合互补传感器仿真案例中所描述的方法评估这里的各反复航迹融合准则的性能。性能评估和比较只针对归一化过程噪声密度  $q/(\sigma_v^2/\Delta T)$  的变化进行。因为对初始位置误差协方差矩阵(由  $\sigma_p$  确定的)或平稳速度误差协方差矩阵(由  $\sigma_v$  确定的)进行改变时,对于相对较长时间的仿真过程,各准则下的航迹融合性能并无明显变化。

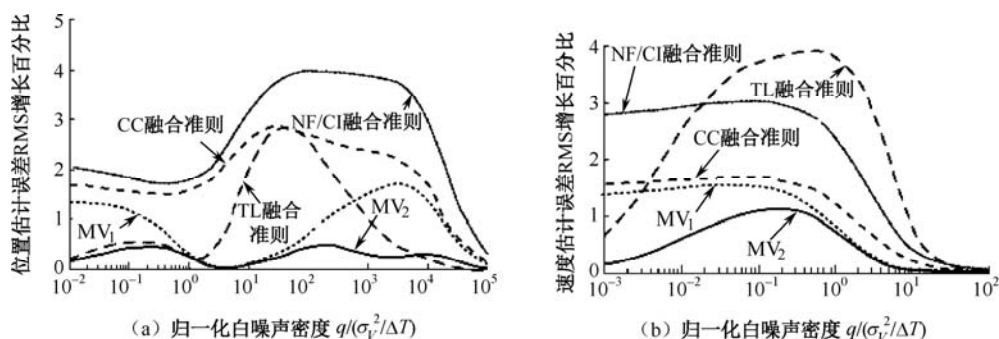


图 6.12 随归一化过程噪声变化的不带反馈航迹融合准则估计误差 RMS 比集中式跟踪误差 RMS 增长的百分比

从图 6.12 可以看出以下几点:

- 与 6.4.3 节一次航迹融合互补传感器各融合准则性能的仿真结果图 6.8 比较,图 12(a)表示的互补传感器反复航迹融合各准则的目标位置估计误差随归一化过程噪声的相对变化趋势基本相同,但没有明显的低  $q$  峰值,并且各准则的估计误差高  $q$  峰值点距离较远。
- 从图 6.12(b)与图 6.8(b)的比较可以看出:在过程噪声  $q$  较小时,速度估计性能比一次航迹融合有明显变化,一次航迹融合当  $q$  较小时,各融合准则的速度估计误差 RMS 趋向于集中跟踪性能,但反复航迹融合当  $q$  较小时,各融合准则的速度估计误差 RMS 与集中跟踪性能相差甚远。当过程噪声  $q$  较大时,两种分布式航迹融合情况各融合准则的速度估计误差 RMS 都趋向于集中跟踪性能。
- 在互补传感器情况下,由于两局部估计误差协方差矩阵不同,故交叉协方差融合准则和凸组合/CI 融合准则的融合权重不同,导致图 6.12(a)、(b)中这两类准则的航迹融合的位置估计和速度估计性能均出现一定差别。
- 由于互补传感器的一次航迹融合与反复航迹融合采用的两互补传感器测量误差协方差矩阵  $\mathbf{R}_{k1}$  和  $\mathbf{R}_{k2}$  都是不随归一化噪声密度变化的相同常矩阵,并且两种分布式融合的 CI/凸组合融合准则都具有相同的标量权值  $\alpha=1/2$ ,故图 6.8 和图 6.12 中的 NF/CI 融合准则的融合性能基本相同。



- 如式 (6.52) 给出的作为反复航迹融合的全记忆极小方差 (MV) 融合准则, 随着目标航迹的不断延续, 使用日益增加的过去目标状态估计需要考虑大量的过去局部估计之间的相关性。图 6.12 中, 我们考虑两种使用局部估计的 MV 估计, 分别称为  $MV_1$  和  $MV_2$ 。 $MV_1$  针对图 6.11 (b) 的两自主传感器系统结构, 其中每个传感器的全局滤波器仅使用两个传感器的最近局部估计, 属于无记忆类准则。此时两传感器系统的全局滤波器具有相同的融合估计结果。每个传感器的系统的全局融合估计是:

$$\hat{\mathbf{x}}_{F_k} = \mathbf{w}_{k_0} \bar{\mathbf{x}}_k + \sum_{i=1}^2 \mathbf{w}_{k_i} \hat{\mathbf{x}}_{k_i}。$$

$MV_2$  针对的是图 6.11 (a) 所示的两传感器单一融合中心的无反馈层次结构, 其中单一融合中心的全局融合估计为

$$\hat{\mathbf{x}}_{F_k} = \mathbf{w}_{k_0} \bar{\mathbf{x}}_k + \sum_{i=1}^2 (\mathbf{w}_{k_i} \hat{\mathbf{x}}_{k_i} + \mathbf{w}_{(k-1)_i} \hat{\mathbf{x}}_{(k-1)_i})$$

不难看出,  $MV_2$  是有限记忆类 (使用最近两周期的局部估计) 融合准则。这两个全局融合公式中的  $\bar{\mathbf{x}}_k$  是基于  $t_{k-1}$  时刻及之前的累计测量对  $t_k$  时刻的目标状态预测。

- 从图 6.12 还可以看出, MV 航迹融合准则的估计性能优于所有与其比较的其他准则。值得注意的是, 当目标的动态是确定性时, 即  $\beta \downarrow 0$  (从而  $q \downarrow 0$ ) 时, 除  $MV_2$  融合准则外, 所有其他融合准则均不收敛于集中跟踪性能。但从图 6.12 能够看到: 在过程噪声密度的很大范围内, 上述各种航迹融合准则的分布式跟踪性能比集中式跟踪性能的恶化仅保持在 1%~5% 较小的相对百分比之内。因此这些简单的航迹融合准则, 如交叉协方差融合准则、NF/CI 融合准则等的性能都是很稳健的。
- 图 6.12 中的小航迹 (TL) 融合准则是 MV 融合准则的解相关形式, 是由 6.5.2 节式 (6.54) 和式 (6.56) 定义的, 被广泛应用于对当前局部估计与上游跟踪器输出的状态估计序列进行解相关, 然后将解除相关的信息 (当前局部估计与伪测量) 输入到一个对多源信息的集中融合引擎当中, 这里输入的解相关信息是状态估计而不是原始测量 (解除的是与过去估计相关的伪测量小航迹估计)。

由于小航迹融合准则使用了传感器局部估计及误差协方差产生解除相关的小航迹, 可以应用集中式融合跟踪公式, 因此小航迹融合准则很实用, 从图 6.12 中的不带反馈局部航迹的小航迹融合结果, 特别是位置估计性能优于交叉协方差融合准则和 NF/CI 融合准则可以看出这一点。

### 6.5.3 带反馈的反复航迹融合

#### 1. 融合结构

带反馈的反复航迹融合在概念上是指图 6.10 (c) 给出的融合中心向两传感器反馈全局航迹融合结果的双向融合信息传输层次结构以及 6.10 (a) 给出的两自主传感器分布式系统中每个传感器都基于相互信息交换产生全局融合航迹的单一层次结构。该结构主要针对两传感器需要自主连续跟踪目标的情况, 通过全局融合信息的反馈传输, 提高局部传感器对目标的自主跟踪能力。然而, 即使对非线性的实际系统采用线性模型的理想近似版本, 该原理在

实现上也有困难。这是由于所采用的某些航迹融合准则尽管对融合时刻的航迹状态估计相当好<sup>[14]</sup>，但很可能被宣布是错误的而不被使用，因其带有不真实的、十分不利的估计误差协方差矩阵，会污染传感器对目标的局部跟踪性能，并且还会产生二次影响，即传感器局部估计对全局融合航迹状态的污染，进而导致全局跟踪性能的恶化。

然而，可以通过一些控制措施抑制恶劣的全局航迹估计对局部跟踪站点的反馈，如文献[67]7.4节描述的部分反馈层次融合，当发现（或基于经验）全局融合估计误差协方差十分不利时，可以仅向局部跟踪站点反馈全局状态估计而不反馈该误差协方差。此外还需要基于已有的先验知识尽量选用避免产生信息相关（重复使用）和一些自适应控制方法，以避免出现恶劣的全局估计结果，使全局反馈信息能够提升局部跟踪性能。

带反馈的反复航迹融合层次结构和自主结构的信息图分别如图 6.13（a）、（b）所示。

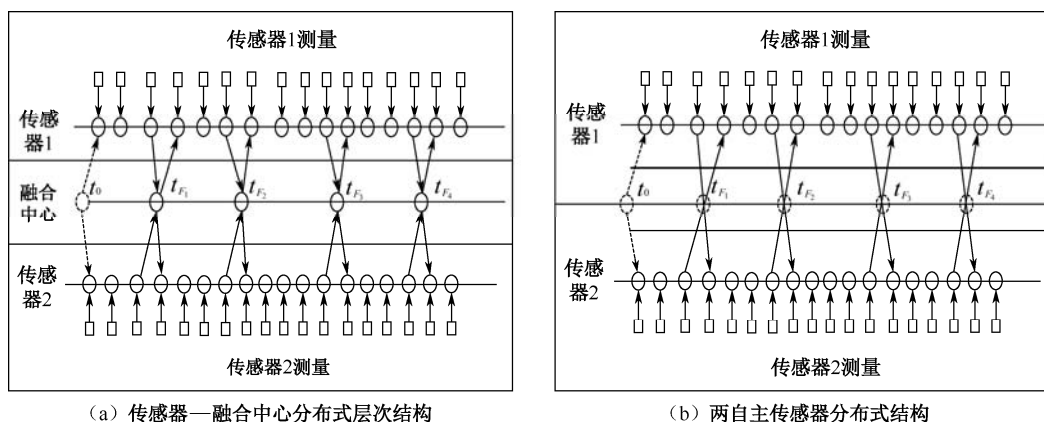


图 6.13 带反馈的反复航迹融合层次结构和自主结构的信息图

图 6.13（a）中，融合中心在  $t_0$  时刻向两传感器发送先验信息（用虚箭头表示）；在  $t_{F_1}, t_{F_2}, t_{F_3}, t_{F_4} \cdots$  时刻，融合中心向两传感器反馈全局航迹状态估计信息（用实箭头表示），两传感器向融合中心传递局部航迹状态信息（用实箭头表示）。每个传感器随即将自身局部估计与同时接收到的全局估计进行融合，以提高自身对目标的自主跟踪能力。在全速率的理想通信信道下，若不考虑融合时间延误，同一时刻向传感器反馈的全局估计中包含了两个传感器同时上报的局部估计信息。因此在传感器处进行融合的局部估计和全局估计具有相关性（信息重用），需要予以解除，否则会增加融合误差。图 6.13（b）所示的带反馈的两自主传感器分布信息图的功能是在图 6.11（b）中无反馈的两自主传感器分布融合信息图所具有的功能基础上，在每个融合时刻  $t_{F_1}, t_{F_2} \cdots$  增加两传感器系统全局航迹相互馈送功能，每个传感器将自身的局部估计与接收到另一传感器的全局航迹进行融合，从而为局部自主跟踪提供更优化性能的目标航迹。

## 2. 融合准则与仿真案例

带反馈反复航迹融合采用的融合准则简述如下：

### ① 交叉协方差、凸组合与协方差交集（CC—NF—CI）准则。

这几个准则与不带反馈反复航迹融合采用的航迹融合准则相同，但在融合过程中，各局

部状态估计及其误差协方差矩阵采用全局融合反馈信息进行修正。

- 由于每个传感器每次目标位置测量的误差协方差矩阵都是对角矩阵，因此所有估计误差协方差矩阵也都是对角矩阵，这样一来，几种 CI 融合准则（最小熵融合准则和极小均方差准则）都变成如前文给出的带有优化加权值  $\alpha=1/2$  的相同形式。
- 由于 Bar Shalom—Campo 的 CC 融合准则考虑了过程噪声引起的相关性，因此其跟踪性能通常优于其他准则。但从 6.3.1 节可知，由于输入的两个局部估计向量之间的交叉协方差预测矩阵  $\bar{V}_{12k}$  和更新估计矩阵  $\hat{V}_{12k}$  计算的复杂性，CC 融合准则并不实用，而其简化的 NF/CI 准则又无法提供真实的融合估计误差协方差矩阵。
- 由于凸组合（NF）融合准则忽略了交叉协方差，通常会导致过分有利的估计误差协方差矩阵，估计误差协方差过小会使人不敢轻易相信；反之，CI 融合准则会产生过分不利的估计误差协方差矩阵，其行列式一般是实际估计误差矩阵的行列式的 4 倍。在这两种情况下，融合中心的全局状态估计向局部站点反馈都会恶化局部传感器的跟踪性能。

### ② 小航迹融合准则。

注意 6.3.2 节中的一次航迹融合的小航迹准则，可知反复航迹融合的小航迹融合准则为

$$\begin{cases} \hat{\mathbf{x}}_{F_k} = \mathbf{V}_{F_k} (\mathbf{V}_{k_1}^{-1} \hat{\mathbf{x}}_{k_1} + \mathbf{V}_{k_2}^{-1} \hat{\mathbf{x}}_{k_2} - \bar{\mathbf{V}}_{F_k}^{-1} \bar{\mathbf{x}}_{F_k}) \\ \mathbf{V}_{F_k}^{-1} = \mathbf{V}_{k_1}^{-1} + \mathbf{V}_{k_2}^{-1} - \bar{\mathbf{V}}_{F_k}^{-1} \end{cases} \quad (6.58)$$

其中  $(\bar{\mathbf{x}}_{F_k}, \bar{\mathbf{V}}_{F_k})$  是上一时刻  $t_{k-1}$  的全局融合估计  $(\hat{\mathbf{x}}_{F(k-1)}, \mathbf{V}_{F(k-1)})$  外推到  $t_k$  时刻的先验预测估计，可以用来消除两个局部估计中由于反馈所包含的冗余信息从而去除重复计算。但值得注意的是，全局融合所得到的估计误差协方差矩阵  $\mathbf{V}_{F_k} = (\mathbf{V}_{k_1}^{-1} + \mathbf{V}_{k_2}^{-1} - \bar{\mathbf{V}}_{F_k}^{-1})^{-1}$  并不真实，通常过分有利，因此将其反馈给局部站点可能会恶化传感器局部估计结果。

### ③ MV 融合准则。

如 6.5.3 节中对不带反馈的反复航迹融合的 MV 准则性能的仿真分析所述，为消除或减少作为全记忆的 MV 航迹融合准则所使用的日益增加的大量过去局部估计与全局估计中的相关性，作为图 6.11 (b) 所示的两个自主传感器分布式跟踪系统的  $MV_1$  准则，仅使用最近

的两个局部估计（无记忆） $\hat{\mathbf{x}}_{Fk} = \mathbf{w}_{k_0} \bar{\mathbf{x}}_k + \sum_{i=1}^2 \mathbf{w}_{ki} \hat{\mathbf{x}}_{k_i}$ 。在带反馈的反复航迹融合情况下，

MV 准则之所以能够应用，是由于最近的各局部估计中包含了全局融合估计反馈给各局部站点的所有有效更新估计信息，并且基于最佳线性无偏估计（BLUE）原则的任一 MV 融合准则都能够产生真实的估计误差协方差矩阵，从而使得全局航迹融合及其对局部站点的反馈不会产生污染扩散。

对上述带有反馈的反复航迹融合的各项融合准则的性能评估的仿真案例，采用与图 6.12 案例同样的互补传感器、同样的线性简化模型及同样的仿真过程。各融合准则产生的目标状态估计性能与集中式跟踪性能的比较如图 6.14 所示。

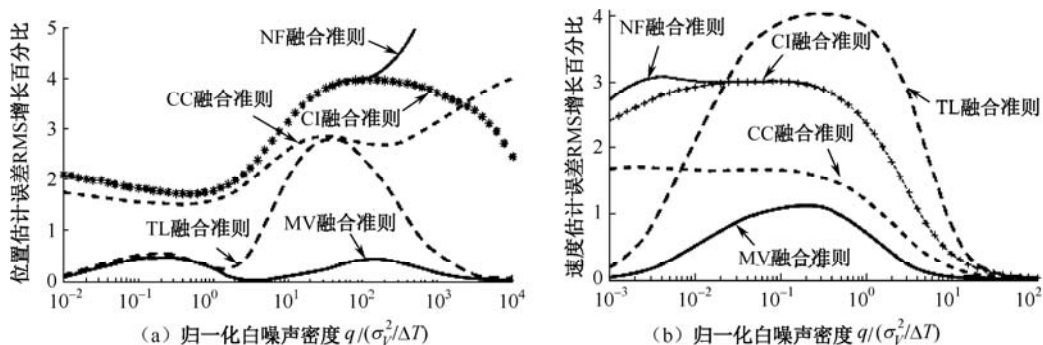


图 6.14 随过程噪声变化的带反馈反复航迹融合各准则估计误差 RMS 比集中式跟踪误差 RMS 增长的百分比

将图 6.14 与前面相应图示比较，可以得出以下几点结论：

- 带反馈反复航迹融合的小航迹准则与无反馈情况相比是相对稳定的，特别是位置误差估计可以作为最接近 MV 航迹融合准则的一个几乎最优的分布式融合算法。
- 随着有限记忆数据的增加，直到无限记忆，采用最优线性无偏估计的 MV 航迹融合准则的性能能够逐渐递增改善。
- 从图 6.14 看到，带反馈的反复航迹融合 CC—NF—CI 准则性能的相对集中跟踪误差变化在一个比较小的 5% 范围内。这样一来，考虑融合时刻所采用的可用信息量以及不真实的（无论是过于不利或过于有利的）全局状态估计误差协方差矩阵反馈所导致的传感器局部跟踪性能的恶化程度等因素，这些简单航迹融合准则的性能均具有一定健壮性（鲁棒性）。
- 比较图 6.6～图 6.9、图 6.12、图 6.14，可以看出一些简单的分布式航迹融合准则（如 CC 融合准则、NF 融合准则和 CI 融合准则）都能够在过程噪声密度的一个较大范围（ $10^{-4} \sim 10^4$  dB）之内提供较好的基于位置和速度的分布式跟踪性能。

## 6.6 分布式航迹关联

如 6.1 节所述，航迹关联是分布式目标跟踪系统的一个关键概念，是航迹融合的前提条件。由于在许多情况（如目标比较稀疏或目标之间、目标与杂波之间易于分辨等情况）下，关联是显而易见的，故在本章前面几节将基于多传感器测量的目标状态估计或多局部航迹融合作为主要问题来描述；而当目标或杂波密度较高，不容易分辨时，航迹关联就变成比航迹融合更重要的问题。在这种情况下，航迹关联与航迹融合功能不再可能完全分离，特别是在分布式跟踪系统的反复航迹融合中，两个问题往往紧密耦合在一起，此时可能出现许多局部航迹关联假设，并且具有相等的可能性。这样一来，最优的局部航迹关联假设可能无法为全局融合提供来自同一目标的高质量局部航迹集合，因为各种关联准则都是按相应的不确定偏差指标产生的，无法统一比较其优劣，此时的航迹关联问题与某些分布式多假设跟踪形式相联系<sup>[22, 28]</sup>。

我们在本节主要面向局部航迹估计性能充分好的情况，即假设局部估计对传感器测量中的不确定性能较好处理，基本上不存在虚假航迹（虚警），也未漏掉真实航迹（漏警）。此时

分布式跟踪可视为一个两阶段问题，即航迹关联作为航迹融合的跟随（伴随）者出现。分布式跟踪中的航迹关联的作用和概念术语是现代估计理论或滤波理论在研究目标跟踪之后不久才发展起来的，近期的研究成果如文献[58, 2]所述。

### 6.6.1 航迹关联的基本假设与评估函数

这里采用 6.2.1 节所描述的线性目标动态与观测模型，目标状态是高斯随机过程。于是我们可以假设采用系统  $[\mathbf{x}_i(t)]_{t \in [t_0, \infty)}]_{i=1}^n$  表示固定数量的  $n$  个“真”目标，该系统的  $n$  个随机变量在  $[t_0, \infty)$  上具有联合初始概率分布：

$$\text{Prob}\{\mathbf{x}_1(t_0) \in d\mathbf{x}_1(t_0), \dots, \mathbf{x}_n(t_0) \in d\mathbf{x}_n(t_0)\} = \prod_{i=1}^n g[\mathbf{x}_i(t_0) - \bar{\mathbf{x}}_0; \bar{\mathbf{V}}_0] d\mathbf{x}_i(t_0) \quad (6.59)$$

式中， $g[\mathbf{x}_i(t_0) - \bar{\mathbf{x}}_0; \bar{\mathbf{V}}_0]$  是目标状态， $\mathbf{x}_i(t_0)$  具有均值为  $\bar{\mathbf{x}}_0$ 、方差为  $\bar{\mathbf{V}}_0$  的高斯分布密度，假设各目标初始状态相互独立。并且如 6.2.1 节式 (6.4) 所定义的，每个独立的随机过程  $[\mathbf{x}_i(t)]_{t \in [t_0, \infty)}$  ( $i = 1, \dots, n$ ) 带有一个白噪声系统  $[\dot{\mathbf{w}}_i(t)]_{t \in [t_0, \infty)}$  或等价的维纳过程  $[\mathbf{w}_i(t)]_{t \in [t_0, \infty)}$  (指离散情况，注意式 (6.9) 和式 (6.10))。

随机变量系统  $[\mathbf{x}_i(t)]_{t \in [t_0, \infty)}]_{i=1}^n$  中的目标分布密度可以采用  $\gamma_0(\mathbf{x}) = ng(\mathbf{x} - \bar{\mathbf{x}}_0; \bar{\mathbf{V}}_0)$  来度量，这样，对于目标状态空间  $E$  的任一子集  $B$ ，积分，可得：

$$\int_B \gamma_0(\mathbf{x}) d\mathbf{x} = n \int_B g(\mathbf{x} - \bar{\mathbf{x}}_0; \bar{\mathbf{V}}_0) d\mathbf{x} \quad (6.60)$$

式 (6.60) 表示子集  $B$  中的期望目标数目，其初始条件  $\mathbf{x}_i(t_0) \in B$ ，即位于子集  $B$  中。

如果目标数目  $n$  不为已知常数，也假设为一个随机变量，则当  $n$  服从泊松分布时， $E$  中的随机变量系统  $[\mathbf{x}_i(t_0)]_{i=1}^n$  也是一个泊松点过程。由于本节的目的旨在比较各种航迹关联的性能度量指标，为简单计，我们在本节仍维持目标数目为常数  $n$  的假设。

为准确描述分布式航迹关联的含义、度量指标及性能比较，采用下述假设：

- 假设两个传感器同时观测目标；
- 假设所有目标都能够被每个传感器观测到；
- 假设每个传感器对目标的局部检测和航迹生成概率为 1；
- 假设没有虚假航迹，即虚警被局部传感器良好的检测性能所淘汰，能够独立产生任一目标航迹。

在上述假设下，每个传感器都能够基于融合时刻  $t_F$  之前的累积观测  $\{\mathbf{z}_{ik}\}_{k=1}^{N_i}$  生成  $n$  条局部估计航迹。于是，我们的航迹关联含义在这里就成为：在融合时刻  $t_F$ ，对两个传感器（或两个局部站点）提供的关于  $n$  个目标的两个局部航迹状态估计集合  $\{\hat{\mathbf{x}}_{1j}(t_F)\}_{j=1}^n$  和  $\{\hat{\mathbf{x}}_{2j}(t_F)\}_{j=1}^n$  进行配对，使每个配对中的两条局部航迹来源于（或表示）同一观测目标。这样，通过对一个配对中的两条局部航迹进行融合就能够产生该目标航迹状态的全局估计。

来自两个传感器的局部航迹的关联配对是通过把局部航迹集合  $\{\hat{\mathbf{x}}_{1j}(t_F)\}_{j=1}^n$  和  $\{\hat{\mathbf{x}}_{2j}(t_F)\}_{j=1}^n$  各元素逐一比较获得的，因此，真实目标与该关联配对产生的全局估计航迹之

间可能不一致。其间的不确定性可以通过相互独立的每个传感器的局部航迹分配函数  $a_i$  ( $i=1,2$ ) 来建模,  $a_1$  和  $a_2$  都是集合  $\{j=1,2,\dots,n\}$  各元素的全排列对应的局部航迹集合。于是这两个局部航迹集合之间的关联配对假设就可以描述为

$$a(j)=[a_1^{-1}(j),a_2(j)]=[j,a_2(j)] \quad (6.61)$$

该式表示来自传感器 1 的第  $j$  条局部航迹与来自传感器 2 的第  $a_2(j)$  条局部航迹是来源于同一目标(或称共享同一信息来源)的关联配对。这样一来,寻找最优关联配对假设就归结为寻求最接近或最有可能的关联配对集合:  $[j,a_2(j)]_{j=1}^n$ , 其评估函数如下:

$$p(a)=C^{-1}\prod_{j=1}^n l[j,a_2(j)] \quad (6.62)$$

式中,  $a=\{a(1),\dots,a(n)\}$  为所有可能的两个  $n$  元素集合的诸元素关联配对策略,最多可能关联的配对数为  $n^2$ ;  $C$  是归一化常数;  $l(j,k)$  是来源于传感器 1 的局部航迹  $j$  与来源于传感器 2 的局部航迹  $k$  的状态估计误差的 ( $1\leq j,k\leq n$ ) 联合似然函数。

在前述一个适宜的假设集合下(如独立、线性高斯状态分布),式(6.62)能够变成基于两个传感器所有局部航迹状态估计的一个可能关联假设  $a$  的后验概率,即

$$p(a)=C^{-1}P_r[a/\hat{x}_{1j}(t_F),\hat{x}_{2j}(t_F)] \quad j=1,\dots,n \quad (6.63)$$

本节中,我们仍将式(6.62)作为该关联配对的假设评估函数,此时可通过局部航迹配对似然函数  $l(j,k)$  或通过其半负对数  $1/2\ln[l(j,k)]$  按  $(j,k)$  的各个全排列配对序列逐一计算关联策略  $a$  的似然函数  $p(a)$ 。

## 6.6.2 航迹关联度量指标及其计算

如 6.6.1 节所述,使用如下半负对数似然函数:

$$L(j,k)=-1/2\ln[l(j,k)] \quad i,j=1,2,\dots,n \quad (6.64)$$

来定义下述关联策略  $a$  的性能度量指标:

$$f(a)=\sum_{j=1}^n L[j,a_2(j)] \quad (6.65)$$

于是可通过使该性能指标,即关联代价达极小来获取最优关联策略  $\hat{a}$ :

$$\hat{a}=\arg\min_a f(a)=\arg\min_a \sum_{j=1}^n L[j,a_2(j)] \quad (6.66)$$

采用式(6.65)定义的关联度量指标  $f(a)$  计算一个关联策略  $a$  的代价意味着要计算传感器 1 第  $j$  条局部航迹与传感器 2 的所有局部航迹  $k$  的关联代价  $L(j,k)$ ,并且按  $j=1,2,\dots,n$  逐一计算。易见这要计算  $n^2$  个航迹配对的可能关联代价  $L(j,k)$   $j,k=1,2,\dots,n$ ,然后形成式(6.65)所示的  $n^2$  个关联配对策略  $a$  的关联代价,并逐一比较,最终确定最优策略  $\hat{a}$ 。

我们下面列出一些最初用作经典  $\chi^2$  检验的指标,但从其结构上看,也可以考虑作为这里的关联度量指标:

① Singer—Kanguck 指标。

在一篇开创性的论文[58]中,提出了该通用的  $\chi^2$  检验指标:

$$L(j, k) = \left\| \hat{\mathbf{x}}_{1j} - \hat{\mathbf{x}}_{2k} \right\|_{(V_{1j} + V_{2k})^{-1}}^2 = (\hat{\mathbf{x}}_{1j} - \hat{\mathbf{x}}_{2k})^T (V_{1j} + V_{2k})^{-1} (\hat{\mathbf{x}}_{1j} - \hat{\mathbf{x}}_{2k}) \quad (6.67)$$

该指标可以用式(6.64)所定义的半负对数似然函数  $L(j, k)$  中两传感器局部航迹的一个配对状态估计误差的联合似然函数  $l(j, k)$  来说明, 容易注意到, 局部航迹配对  $(j, k)$  的似然函数为

$$\begin{aligned} l(j, k) &= \int_E \hat{p}_{1j}(\mathbf{x}) \hat{p}_{2k}(\mathbf{x}) d\mathbf{x} \\ &= \int_E g(\mathbf{x} - \hat{\mathbf{x}}_{1j}; V_{1j}) g(\mathbf{x} - \hat{\mathbf{x}}_{2k}; V_{2k}) d\mathbf{x} \\ &= g(\hat{\mathbf{x}}_{1j} - \hat{\mathbf{x}}_{2k}; V_{1j} + V_{2k}) \end{aligned} \quad (6.68)$$

我们将该联合正态分布密度:

$$g(\hat{\mathbf{x}}_{1j} - \hat{\mathbf{x}}_{2k}; V_{1j} + V_{2k}) = \frac{1}{\sqrt{2\pi \det(V_{1j} + V_{2k})}} \exp\left[-\frac{1}{2}(\hat{\mathbf{x}}_{1j} - \hat{\mathbf{x}}_{2k})^T (V_{1j} + V_{2k})^{-1} (\hat{\mathbf{x}}_{1j} - \hat{\mathbf{x}}_{2k})\right]$$

中的因子  $\det[2\pi(V_{1j} + V_{2k})]^{-\frac{1}{2}}$  或其半负对数  $\ln[\det 2\pi(V_{1j} + V_{2k})]$  作为所有关联配对似然函数的一个共用常数予以删除, 则该正态分布密度的半负对数就成为 Singer—Kanguck 提出的  $\chi^2$  度量指标。

## ② Bar Shalom 指标。

论文[2]中提出的该指标是:

$$L(j, k) = \left\| \hat{\mathbf{x}}_{1j} - \hat{\mathbf{x}}_{2k} \right\|_{(V_{1j} + V_{2k} - V_{12jk} - V_{12jk}^T)^{-1}}^2 \quad (6.69)$$

作为用于对航迹关联配对的  $\chi^2$  检验指标, 式中的  $V_{12jk}$  是传感器 1 航迹  $j$  与传感器 2 航迹  $k$  估计误差的交叉协方差, 这是假设其具有同一目标状态噪声和先验信息产生的。式(6.69)可以解释为等同于如下似然函数的半负对数:

$$\begin{aligned} l(j, k) &= \int_E g\left(\begin{bmatrix} \mathbf{x} - \hat{\mathbf{x}}_{1j} \\ \mathbf{x} - \hat{\mathbf{x}}_{2k} \end{bmatrix}; \begin{bmatrix} V_{1j} & V_{12jk} \\ V_{12jk}^T & V_{2k} \end{bmatrix}\right) d\mathbf{x} \\ &= g(\hat{\mathbf{x}}_{1j} - \hat{\mathbf{x}}_{2k}; V_{1j} + V_{2k} - V_{12jk} - V_{12jk}^T) \end{aligned} \quad (6.70)$$

事实上, 当我们将式(6.70)所示的正态分布  $g(\hat{\mathbf{x}}_{1j} - \hat{\mathbf{x}}_{2k}; V_{1j} + V_{2k} - V_{12jk} - V_{12jk}^T)$  中的因子  $\det[2\pi(V_{1j} + V_{2k} - V_{12jk} - V_{12jk}^T)]^{-\frac{1}{2}}$  或其半负对数  $\ln\{\det[2\pi(V_{1j} + V_{2k} - V_{12jk} - V_{12jk}^T)]\}$  作为所有关联配对似然函数的一个共用常数予以删除时, 该正态分布密度的半负对数就成为式(6.69)所示的 Bar Shalom 指标。

## ③ CI 指标。

迄今为止, 尚未出现基于 CI 原理的局部航迹关联指标, 但是基于①、②所描述的两个航迹关联度量指标的原理, 注意 CI 融合公式(6.32), 我们在这里可以定义一个适宜的 CI 航迹关联指标:

$$L(j, k) = \left\| \hat{\mathbf{x}}_{1j} - \hat{\mathbf{x}}_{2k} \right\|_{[\hat{\alpha}_{jk}^{-1} \mathbf{V}_{1j} + (1 - \hat{\alpha}_{jk}) \mathbf{V}_{2k}]^{-1}}^2 \quad (6.71)$$

式(6.71)可以解释为等同于如下似然函数的半负对数:

$$\begin{aligned} l(j, k) &= \int_E \hat{p}_{1j}(\mathbf{x})^{\hat{\alpha}_{jk}} \hat{p}_{2k}(\mathbf{x})^{(1 - \hat{\alpha}_{jk})} d\mathbf{x} \\ &= \int_E g(\mathbf{x} - \hat{\mathbf{x}}_{1j}; \mathbf{V}_{1j})^{\hat{\alpha}_{jk}} g(\mathbf{x} - \hat{\mathbf{x}}_{2k}; \mathbf{V}_{2k})^{(1 - \hat{\alpha}_{jk})} d\mathbf{x} \end{aligned} \quad (6.72)$$

事实上, 当我们将式(6.72)右端积分中的两正态分布密度  $g(\mathbf{x} - \hat{\mathbf{x}}_{1j}; \mathbf{V}_{1j})^{\hat{\alpha}_{jk}}$  和  $g(\mathbf{x} - \hat{\mathbf{x}}_{2k}; \mathbf{V}_{2k})^{(1 - \hat{\alpha}_{jk})}$  乘积中的因子:

$$\frac{\det(\mathbf{V}_{1j})^{\alpha_{jk}} \det(\mathbf{V}_{2k})^{1 - \alpha_{jk}}}{\det[(1 - \alpha_{jk}) \mathbf{V}_{1j} + \alpha_{jk} \mathbf{V}_{2k}]}$$

或其半负对数作为所有关联配对似然函数的共用常数予以删除时, 式(6.72)的半负对数就成为这里定义的 CI 航迹关联指标。式(6.71)和式(6.72)中最优指数权值  $\hat{\alpha}_{jk}$  如 6.3.2 节所述, 可以通过使行列式  $\det[\alpha \mathbf{V}_{1j}^{-1} + (1 - \alpha) \mathbf{V}_{2k}^{-1}]$  达极小 (即对应最小熵的香农准则), 或是该行列式的迹达极小 (即对应极小均方误差的 Chen—Arambel—Mehra 准则) 来选择。

#### ④ Chong—Mori—Chang 指标。

假设两传感器局部航迹关联结果不产生虚关联 (可能产生虚假全局航迹) 和漏关联 (可能会漏掉全局航迹), 我们能够证明, 式(6.63)所示的贝叶斯航迹关联假设评估函数中所使用的航迹关联似然函数  $l(j, k)$  可由下式给出:

$$\begin{aligned} l(j, k) &= \int_E \frac{\hat{p}_{1j}(\mathbf{x}) \hat{p}_{2k}(\mathbf{x})}{\bar{p}(\mathbf{x})} d\mathbf{x} = \int_E \frac{g(\mathbf{x} - \hat{\mathbf{x}}_{1j}; \mathbf{V}_{1j}) g(\mathbf{x} - \hat{\mathbf{x}}_{2k}; \mathbf{V}_{2k})}{g(\mathbf{x} - \bar{\mathbf{x}}; \bar{\mathbf{V}})} d\mathbf{x} \\ &= \left( \frac{\det(\bar{\mathbf{V}}) \det(\hat{\mathbf{V}}_{Fjk})}{\det(\mathbf{V}_{1j}) \det(\mathbf{V}_{2k})} \right)^{1/2} \exp \left( -\frac{1}{2} \left( \left\| \hat{\mathbf{x}}_{Fjk} - \hat{\mathbf{x}}_{1j} \right\|_{\mathbf{V}_{1j}^{-1}}^2 + \left\| \hat{\mathbf{x}}_{Fjk} - \hat{\mathbf{x}}_{2k} \right\|_{\mathbf{V}_{2k}^{-1}}^2 - \left\| \hat{\mathbf{x}}_{Fjk} - \bar{\mathbf{x}} \right\|_{\bar{\mathbf{V}}^{-1}}^2 \right) \right) \end{aligned} \quad (6.73)$$

式中,  $\bar{p}(\mathbf{x}) = g(\mathbf{x} - \bar{\mathbf{x}}; \bar{\mathbf{V}})$  是融合时刻  $t_F$  的目标状态  $\mathbf{x} = \mathbf{x}(t_F)$  的一个先验概率密度。

$(\hat{\mathbf{x}}_{Fjk}, \hat{\mathbf{V}}_{Fjk})$  是一对局部航迹  $\hat{\mathbf{x}}_{1j}$  与  $\hat{\mathbf{x}}_{2k}$  融合状态估计与估计误差协方差矩阵, 可以基于小航迹融合准则的定义式(6.21)获得

$$\begin{cases} \hat{\mathbf{V}}_{Fjk}^{-1} \hat{\mathbf{x}}_{Fjk} = \mathbf{V}_{1j}^{-1} \hat{\mathbf{x}}_{1j} + \mathbf{V}_{2k}^{-1} \hat{\mathbf{x}}_{2k} - \bar{\mathbf{V}}^{-1} \bar{\mathbf{x}} \\ \hat{\mathbf{V}}_{Fjk}^{-1} = \mathbf{V}_{1j}^{-1} + \mathbf{V}_{2k}^{-1} - \bar{\mathbf{V}}^{-1} \end{cases} \quad (6.74)$$

式中假设所有传感器  $\hat{\mathbf{x}}_{1j}$  与  $\hat{\mathbf{x}}_{2k}$  来源于同一目标。尽管小航迹融合规则式(6.21)仅当目标动态是确定性的, 即没有过程噪声 ( $B_t \equiv 0$ ) 时, 用于上述航迹关联评估的似然函数才是正确的; 但是, 通过小航迹融合规则对非确定性动态外推估计进行组合, 航迹关联似然函数式(6.73)也能够适应非确定性动态情况。

当式(6.73)中 4 个行列式因子能够相约时, 可以将它们作为所有关联配对的似然函数的共用常数予以删除, 这样一来, 式(6.73)所示的似然函数的半负对数就成为



$$l(j, k) = \|\hat{\mathbf{x}}_F - \hat{\mathbf{x}}_{1j}\|_{V_{1j}^{-1}}^2 + \|\hat{\mathbf{x}}_F - \hat{\mathbf{x}}_{2k}\|_{V_{2k}^{-1}}^2 - \|\hat{\mathbf{x}}_F - \bar{\mathbf{x}}\|_{P^{-1}}^2 \quad (6.75)$$

式中,  $\hat{\mathbf{x}}_F = \hat{\mathbf{x}}_{Fjk}$ , 由式(6.74)确定。

#### ⑤ 扩展状态指标。

该指标是通过目标状态从一个融合时刻  $t_F$  的状态  $\mathbf{x}(t_F)$  扩展到时间区间  $[t_0, t_F]$  中的多个时刻  $t_1, t_2, \dots, t_n$  的状态获得的。如果集合  $(t_1, \dots, t_n)$  涵盖了两个传感器的所有测量时刻  $\{t_{1k}\}_{k=1}^{N_1}$  和  $\{t_{2k}\}_{k=1}^{N_2}$ , 我们就可以将6.2.1节所定义的非确定性动态方程(6.3)重新用一个确定性方程描述, 其中目标的确定性状态是  $[\mathbf{x}(t_1), \dots, \mathbf{x}(t_n)]$ , 而不是单一状态  $\mathbf{x}(t_F)$ 。在该扩展方式下, 过程噪声  $\dot{\mathbf{w}}(t_1), \dots, \dot{\mathbf{w}}(t_n)$  产生的所有不确定性都被变换为不同时刻目标状态之间的交叉协方差。这样一来, 应用上述Chong—Mori—Chang航迹关联度量指标(6.73)或(6.75), 航迹关联假设的评估函数(6.62)就真正成为贝叶斯意义下的每个关联假设策略的后验概率式(6.63)。求解这个经典的二元分配问题, 我们就可以得到极大后验(MAP)意义下的最优关联策略  $\hat{a}$ 。

值得指出的是, 在严格的意义上, 仅当目标数目已知, 并且既不存在漏警(遗漏目标)又不存在虚警(虚假目标)时, 航迹关联评估函数式(6.62)才是合理的。

在目标遗漏情况下, 会存在不成对(即无法配对)的局部航迹, 此时, 按文献[51]和[30]所给出的结果, 每个局部航迹关联假设需要根据目标密度估计加以调整。当目标数目的先验分布不符合泊松分布时, 关联假设评估函数(6.62)中的归一化常数  $C$  取决于成对的和不成对的航迹数目。当然在存在虚假航迹情况时, 在理论上要更加复杂, 在文献[10]中, 可以找到这种情况的局部航迹关联指标的一个定义, 关于该问题的最近理论研究成果可以在文献[53]中找到。

本节给出的各项航迹关联度量指标均涉及进行关联配对的两条局部航迹估计之间的距离、方差、协方差等关系参数, 有的指标甚至涉及这两条局部航迹估计的融合结果。这样看来, 分布式跟踪系统中的航迹关联与航迹融合如影随形、密不可分, 或者说航迹关联无法脱离航迹融合而独立存在, 这是与集中式融合的一个重要差别。必须指出的是, 传感器测量误差也与航迹关联密切相关, 传感器测量误差传递到局部航迹估计中, 产生局部航迹之间的“距离”、方差和协方差, 对航迹关联的正确性起着重要影响, 因此航迹关联与传感器测量误差无法分离。为了消除传感器测量误差对航迹关联的影响, 航迹关联指标可以通过传感器测量误差的概率分布进行修正, 如文献[43, 52, 30]所述。

### 6.6.3 航迹关联度量指标比较仿真案例

在本节中, 我们采用航迹关联评估函数式(6.62)来检验6.6.2节所给出的各种航迹关联指标, 比较和评价各关联指标的性能。为此, 采用如下仿真案例。

#### 1. 剧情模型与仿真过程

这里仍采用6.4.1节所描述的简单线性剧情模型, 即Ornstein—Uhlenbeck目标动态模型, 并且采用两个互补传感器观测空中目标, 仿真生成这样的态势: 每个传感器都能够较好地

空中目标分离为一组高质量的局部航迹集合  $\{\hat{\mathbf{x}}_{1j}\}_{j=1}^{N_1}$ 、 $\{\hat{\mathbf{x}}_{2k}\}_{k=1}^{N_2}$ 。在两个传感器产生的局部航迹之间存在显著的不确定性,如图 6.15 所示。

图 6.15 是具有  $90^\circ$  观测视角差的两个互补传感器各自生成的 3 个空中目标的局部航迹及其不正确性范围,其中每个局部航迹估计点是基于 10 个时刻的同步测量生成的,其不确定性范围用一个误差椭圆表示,两传感器产生的局部航迹误差椭圆主轴相互垂直。




图 6.15 两个互补传感器产生的局部航迹

为进行蒙特卡洛仿真,仿真实验过程采用 6.6.1 节(实际上是 6.2.1 节)描述的线性高斯模型和 6.4.1 节给出的 O—U 目标动态模型参数以及联合高斯分布的初始条件,生成 100 个目标随机集合。每条局部目标航迹都采用 10 个局部测量生成。每个目标初始位置不确定性标准差相同,都是测量误差的 10 倍,即  $\sigma_p = 10\sigma_m$ 。

该仿真验证过程的自变量是归一化过程噪声密度  $q/(\sigma_v^2/\Delta T)$  和目标初始位置不确定性标准差  $\sigma_p$ , 进行比较的航迹关联指标是 Bar Shalom 指标、Singer—Kanguck 指标、Chong—Mori—chang 指标和扩展状态指标。如图 6.15 所示,该仿真过程采用具有  $90^\circ$  观测视角差的两个互补传感器,其测量误差协方差矩阵是对角矩阵,使 CI 融合准则权重相等,即  $\alpha=1/2$ ,对应的 CI 航迹关联指标由带有权重  $\alpha_{jk}=1/2$  的式(6.71)来定义,该权重使 CI 关联指标与 Singer—Kanguck 指标相同。

每个航迹关联指标的仿真性能都采用其所能够实现的正确关联概率表示。在仿真实验中,正确关联概率是基于统计结果产生的。仿真过程如下:

- ① 基于假设剧情,产生 100 批目标的“真实”航迹。
- ② 对于每批目标的每个航迹点,两个传感器独立仿真生成各自的 10 个时刻的同步测量,然后按某种滤波方法,生成相应航迹点估计位置  $\hat{\mathbf{x}}_{1i}, \hat{\mathbf{x}}_{2i}$  及其误差协方差  $V_{1i}, V_{2i} (i=1, 2, \dots)$ 。
- ③ 按照要评估的 4 项航迹关联指标公式,分别计算每个关联配对的关联指标值,然后生成式(6.62)所示的相应关联策略的评估函数  $p(a)$ 。
- ④ 比较各关联策略  $a$  的评估函数  $p(a)$  值,确定最优关联策略  $\hat{a}$ 。

⑤ 基于获得的最优关联策略  $\hat{a}$ ，对每一个目标，查看来源于该目标的局部航迹是否被正确关联，即一个航迹配对中的两条局部航迹是否都来源于该目标。在仿真实验中，通常由剧情设计者确定某一传感器产生的局部航迹是否为一个真实的目标航迹，然后检验来源于该目标的另一个传感器的局部航迹在最优策略  $\hat{a}$  中是否正确地分配给该指定的传感器“真实”航迹。

⑥ 采用正确关联目标数在总目标数中所占比例，通过 1 000 个仿真样本，统计确定每项航迹关联指标仿真实验获得的航迹正确关联概率。

## 2. 航迹关联度量指标仿真结果分析

图 6.16 给出了 4 项关联指标的航迹关联性能的仿真验证结果，通过各项关联指标产生的正确关联概率随归一化噪声密度和归一化初始位置标准差的变化情况来表示。

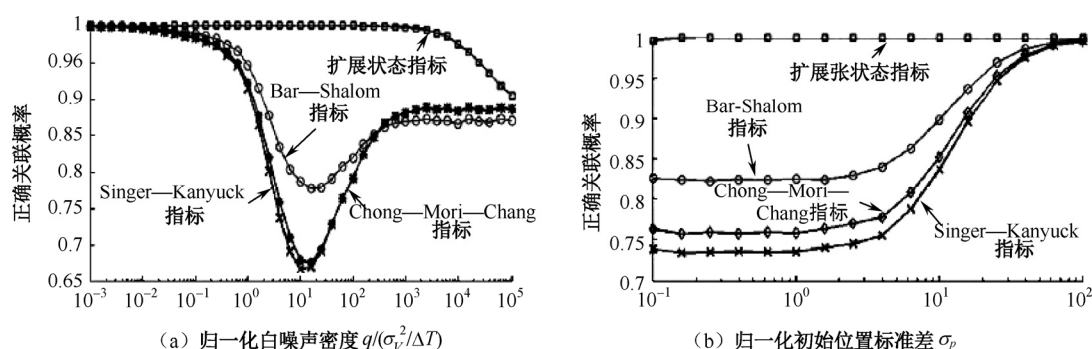


图 6.16 4 项航迹关联指标性能随归一化噪声密度和归一化初始位置标准差的变化情况

从图中可得出如下几点结论：

- 从图 6.16 (a)、(b) 可以清晰地看出，采用两传感器局部估计之间交叉协方差矩阵的航迹关联指标，即 Bar Shalom 关联指标的性能优于不采用交叉协方差矩阵的 Singer—Kanguck 关联指标和 Chong—Mori—Changhn 关联指标；
- 图 6.16 (a) 中，在归一化过程噪声  $q$  的中部区域 ( $10^0 \sim 10^2$  dB 范围内)，除扩展状态的航迹关联指标外的其他 3 项航迹关联指标都出现关联性能恶化，这是由于在所采用的 O—U 目标动态模型 (见 6.4.1 节) 的性能图 6.5 (c) 中，这一过程噪声范围内的目标融合先验状态不确定性比较大，从而对联合目标状态密度产生了影响；
- Chong—Mori—Chang 航迹关联指标使用两配对航迹的先验状态均值  $(\bar{x}, V)$ ，从图 6.16 (a)、(b) 都能看出，它比采用 Singer—Kanguck 关联指标能产生更好的关联性能，但差别并不大，这是由于每个局部航迹采用 10 次局部测量，能够减少先验状态的影响；
- 几乎在所有情况下，扩展状态航迹关联指标的关联性能都优于其他指标的关联性能，这是由于其考虑了两次融合之间的多个测量时刻的状态估计，而不是仅考虑一个融合时刻的状态估计。

## 6.7 本章小结

本章讨论了作为分布式多目标跟踪要点的航迹融合与航迹关联问题。首先通过介绍航迹相关在分布式融合与集中式融合中完全不同的概念和内涵,描述了分布式多目标跟踪中的航迹关联概念和内涵,并指出了航迹融合与航迹关联的不可分性,特别在航迹关联性能度量指标中阐述了二者如影随形的密切关系。

本章回顾了近三十年来提出的多个航迹融合准则和算法,使用线性高斯模型建立了近似于集中式跟踪性能的 Koch—Govaers 融合基准,采用 Ornstein—Uhlenbeck 目标动态模型建立了仿真案例,通过仿真实验,在分布式局部航迹一次融合与目标连续跟踪中局部航迹反复融合的背景下,特别针对全局融合结果对局部站点反馈和不反馈两种反复航迹融合的情况,重点对追加传感器和互补传感器两种配置,验证并比较了各项航迹融合准则的性能。基于仿真实验结果各融合准则性能的比较表明,除严格贝叶斯极大似然(BML)融合准则外,有些航迹融合准则在其适应的某些态势下,性能优于其他融合准则;但总体说来,常见的简单实用的航迹融合准则,如凸组合(NF)、极小方差(MV)、最佳线性无偏估计(BLUE)、交叉协方差(CC)以及解相关的小航迹(TL)等融合准则在性能上比集中式跟踪(采用 Koch—Govaers 融合方法)性能略差(<5%)。当然,在分布式跟踪环境下,选择适当的航迹融合准则还需要考虑通信带宽需求、实现难度、健壮性等因素。

本章建立了5种航迹关联度量指标和统一的航迹关联性能评估函数,并采用简单的高斯线性模型和 Ornstein—Uhlenbeck 动态模型参数构建典型多目标态势,对各航迹关联性能指标进行了仿真验证和比较。仿真实验结果表明,对于两互补传感器观测的情况,考虑源于同一目标的两传感器局部航迹的交叉协方差的 Bar Shalom 指标的航迹关联性能要比没考虑该交叉协方差的 Singer—Kanguck 指标和 Chong—Mori—Chang 航迹关联指标要好。与此同时,需要多时刻测量和多计算量的扩展状态向量航迹关联指标要比其他所有航迹关联指标的性能更好,这并不奇怪,因为目标机动时,难以形成与机动状态估计关联的航迹。因此,在高不确定目标动态情况下,使用扩展状态向量的航迹关联度量指标会产生更好的航迹关联性能。

## 参考文献

- [1] Anderson B D O, J B Moore. Optimal Filtering. Englewood Cliffs, NJ: Prentice-Hall, 1979.
- [2] Bar-Shalom Y, On the track-to-track correlation problems. IEEE Transactions on Automatic Control AC, 1981, 26(2): 571 - 572.
- [3] Bar-Shalom Y, L Campo. The effect of the common process noise on the two-sensor fused-track covariance. IEEE Transactions on Aerospace and Electronic Systems AES, 1986, 22(6): 803 - 805.
- [4] Bar-Shalom Y, T E Fortmann. Tracking and Data Association. San Diego, CA: Academic Press, 1988.
- [5] Bar-Shalom Y, X. R Li. Estimation and Tracking: Principles, Techniques and Software. Dedham, MA: Artech

- House, 1993.
- [6] Bar-Shalom Y, X R Li, T Kirubarajan. Estimation with Applications to Tracking and Navigation: Theory, Algorithms, and Software. New York: John Wiley & Sons, 2001.
- [7] Bar-Shalom Y, P K Willet, X Tian. Tracking and Data Fusion: A Handbook of Algorithms. Storrs, CT: YBS Publishing, 2011.
- [8] Belkin B, S L Anderson, K M Sommar. The pseudomeasurement approach to track-to-track data fusion. Proceedings of the 1993 Joint Service Data Fusion Symposium, Laurel, MD, 1993, 519 – 538.
- [9] Blackman S S. Multiple-Target Tracking with Radar Application. Norwood, MA: Artech House, 1986.
- [10] Blackman . S. R, Popoli. Design and Analysis of Modern Tracking Systems. Norwood, MA: Artech House, 1999.
- [11] Bourgault F H F Durrant-Whyte. Communication in general decentralized filters and the coordinated search strategy. Proceedings of the 7th International Conference on Information Fusion, Stockholm, Sweden, 2004, 723 – 730.
- [12] Chang K C, C Y Chong, S Mori. On scalable distributed sensor fusion. Proceedings of the 11th International Conference on Information Fusion, Cologne, Germany, 2008.
- [13] Chang K C, R K Saha, Y Bar-Shalom. On optimal track-to-track fusion. IEEE Transactions on Aerospace and Electronic Systems, 1997, 33(4): 1271 – 1276.
- [14] Chang K C, Z Tian, R K Saha. Performance evaluation of track fusion with information matrix filter. IEEE Transactions on Aerospace and Electronic Systems, 2002, 38(2): 455 – 466.
- [15] Chen L, P O Arambel, R K Mehra. Estimation under unknown correlation: Covariance intersection revised. IEEE Transactions on Automatic Control, 2002, 47(11): 1879 – 1882.
- [16] Chong C Y. Hierarchical estimation. Proceedings of the MIT/ONR Workshop on C3, Monterey, CA, 1979.
- [17] Chong C Y, E Tse, S Mori. Distributed estimation in network. Proceedings of the 83 American Control Conference, San Francisco, CA, 1983.
- [18] Chong C Y, S Mori. Convex combination and covariance intersection algorithms in distributed fusion. Proceedings of the 4th International Conference in Information Fusion, Montreal, Quebec, Canada, 2001.
- [19] Chong C Y, S Mori, K C Chang. Information fusion in distributed sensor networks. Proceedings of the 1985 American Control Conference, Boston, MA, 1985, 830 – 835.
- [20] Chong C Y, K C Chang, S Mori. Distributed tracking in distributed sensor networks. Proceedings of the 1986 American Control Conference, Seattle, WA, 1986.
- [21] Chong C Y, S Mori, K C Chang. Adaptive distributed estimation. Proceedings of the 26th IEEE Conference on Decision and Control, Los Angeles, CA, 1987, 2233 – 2238.
- [22] Chong C Y, S Mori, K C Chang. Distributed multitarget multisensory tracking (Chapter 8). In Multitarget-Multisensor Tracking: Advanced Applications. Y. Bar-Shalom (Ed.), 1990, 247 – 295.
- [23] Chong C Y, S Mori, K C Chang, et al. Architectures and algorithms for track association and fusion. IEEE Aerospace and Electronic Systems Magazine, 2000, 15: 5 – 13.

- [24] Cover T M, J A Thomas. Elements of Information Theory. New York: John Wiley & Sons, 2006.
- [25] Drummond O E. Track fusion with feedback. Proceedings of the SPIE Symposium on Sensor and Data Processing of Small Targets, Orlando, FL, 1996, Vol. 2759, 342 – 360.
- [26] Drummond O E.. A hybrid sensor fusion algorithm architecture and tracklets. Proceedings of the SPIE Symposium on Signal and Data Processing of Small Targets, San Diego, CA. 1997a, Vol. 3163.
- [27] Drummond O E. Tracklets and a hybrid fusion with process noise. Proceedings of the SPIE Symposium on Signal and Data Processing of Small Targets, San Diego, CA, 1997b, Vol. 3163.
- [28] Dunham D T, S S Blackman, R J Dempster. Multiple hypothesis tracking for a distributed multiple platform system. Proceedings of the SPIE Symposium on Signal and Data Processing of Small Targets, Orlando, FL, 2004, 13 – 15.
- [29] Durrant-Whyte H F, B S Y Rao, H Hu. Toward a fully decentralized architecture for multi-sensor data fusion. Proceedings of the IEEE International Conference on Robotic Automation, Cincinnati, OH, 1990, 1331 – 1336.
- [30] Ferry J P Exact association probability for data with bias and feature. Journal of Advances in Information Fusion, 2010, 5(1): 41 – 66.
- [31] Gao Y, X R Li. Quasi-tracklet fusion accounting for cross-correlation. Proceedings of the 13th International Conference on Information Fusion, Edinburgh, U K, 2010.
- [32] Govaers F, W Koch. Distributed Kalman filter fusion at arbitrary instants of time. Proceedings of the 13th International Conference on Information Fusion, Edinburgh, U K, 2010.
- [33] Govaers F, W Koch. On the globalized likelihood function for exact track-to-track fusion at arbitrary instants of time. Proceedings of the 14th International Conference on Information Fusion, Chicago, IL, 2011.
- [34] Hashemipour H R, S Roy, A J Laub. Decentralized structures for parallel Kalman filtering. IEEE Transactions on Automatic Control AC, 1988, 33: 88 – 93.
- [35] Hurley M An information-theoretic justification for covariance intersection and its generalization. Proceedings of the 5th International Conference on Information Fusion, Annapolis, MD, 2002.
- [36] Iyengar S S, R R Brook. Distributed Sensor Networks. Chapman & Hall CRC Computer & Information Science Series. Boca Raton, FL: CRC Press, 2005.
- [37] Julier S J. An empirical study into the use of Chernoff information for robust, distributed fusion of Gaussian mixture models. Proceedings of the 8th International Conference on Information Fusion, Florence, Italy, 2006.
- [38] Julier S J, J K Uhlmann, J Walters, et al. The challenge of scalable and distributed fusion of disparate sources of information. Proceedings SPIE Conference on Multisensor, Multisource Information Fusion: Architectures, Algorithms, and Applications, Orlando, FL, 2006, Vol. 6242.
- [39] Kalman R E.. A new approach to linear filtering and prediction problems. Transactions of ASME—Journal of Basic Engineering, Series D, 1960, 82: 35 – 45.
- [40] Kalman R E, R S Bucy. New results in linear filtering and prediction theory. Transactions of ASME—

- Journal of Basic Engineering, 1960, 83: 95 – 108.
- [41] Koch W. On optimal distributed Kalman filtering and retrodiction at arbitrary communication rates for maneuvering targets. Proceedings of the IEEE International Conference on Multisensor Fusion and Integration for Intelligence Systems (MFI 2008), Seoul, Korea, 2008, 457 – 462.
- [42] Koch W. Exact update formulae for distributed Kalman filtering and retrodiction at arbitrary communication rates. Proceedings of the 12th International Conference on Information Fusion, Seattle, WA, 2009, 2209 – 2216.
- [43] Levedahl M. An explicit pattern matching assignment algorithm. Proceedings of SPIE Symposium on Signal and Data Processing of Small Targets, Orlando, FL. 2002, Vol. 4728.
- [44] Li X R, Y Zhu, J Wang, et al. Optimal linear estimation fusion—Part I: Unified fusion rules. IEEE Transactions on Information Theory, 2003, 49: 9.
- [45] Liggins II, M E, K C Chang. Distributed fusion architectures, algorithms, and performance within a network-centric architecture. In Handbook of Multisensor Data Fusion: Theory and Practice. Boca Raton, FL: CRC Press, 2009.
- [46] Liggins II, M E, C Y Chong, I Kadar, et al. Distributed fusion architecture and algorithms for target tracking. Proceedings of the IEEE, 1997, 85: 95 – 107.
- [47] Lobb R, M Kent. Data fusion of decentralized tracker outputs. IEEE Transactions on Aerospace and Electronic Systems, 1994, 30: 787 – 799.
- [48] Miller M D, O E Drummond, A J Perrella. Tracklets and covariance truncation options for theater missile tracking. Proceedings of the 1st International Conference on Multisource-Multisensor Data Fusion, Las Vegas, NV, 1998.
- [49] Moore J R, W D Blaire. Practical aspects of multisensor tracking (Chapter 1). Multitarget-Multisensor Tracking—Applications and Advances, Boston, MA: Artech House, 2000.
- [50] Mori S, W H Barker, C Y Chong, et al. Track association and track fusion with non-deterministic target dynamics. IEEE Transaction on Aerospace and Electronic Systems, 2002, 38(2): 659 – 668.
- [51] Mori S, C Y Chong. Track-to-track association metric. Proceedings of the 6th International Conference on Information Fusion, Cairns, Queensland, Australia, 2003.
- [52] Mori S, C Y Chong. Comparison of bias removal algorithms in track-to-track association. Proceedings of SPIE Symposium on Signal and Data Processing of Small Targets, San Diego, CA, 2007, Vol. 6699,
- [53] Mori S, C Y Chong, K C Chang. Track association and fusion using Janossy measure density functions. Proceedings of the 12th International Conference on Information Fusion, Seattle, WA, 2009.
- [54] Nicholson D, S J Julier, J K Uhlmann. DDF: An evaluation of covariance intersection. Proceedings of the 4th International Conference on Information Fusion, Montreal, Quebec, Canada, 2001.
- [55] Nicholson D, C M Lloyd, S J Julier, et al. Scalable distributed data fusion. Proceedings of the Fifth International Conference on Information Fusion, Annapolis, MD, 2002, 630 – 635.
- [56] Rao B S Y, H F Durrant-Whyte, J A Sheen. Fully decentralized multi-sensor system for tracking and

- surveillance. *International Journal of Robotics Research*, 1993, 12(1): 20 – 44.
- [57] Rhodes I B A tutorial introduction to estimation and filtering. *IEEE Transactions on Automatic Control AC*, 1971, 16(6): 688 – 706.
- [58] Singer R A, A J Kanyuck. Computer control of multiple site correlation. *Automatica*, 1971, 7: 455 – 463.
- [59] Speyer J L. Computation and transmission requirements for a decentralized linearquadratic-Gaussian control problem. *IEEE Transactions on Automatic Control AC*, 1979, 24: 266 – 269.
- [60] Vebber P W. An examination of target tracking in the antisubmarine warfare system evaluation tool (ASSET), Master thesis, Naval Postgraduate School, Monterey, CA, 1991.
- [61] Washburn A. Probability density of a moving particle. *Operations Research*, 1969, 17(5): 861 – 871.
- [62] Wiener N. *Extrapolation, Interpolation, and Smoothing of Stationary Time Series*. New York: Technology Press of MIT, 1949.
- [63] Zhu Y, X R Li. Best linear unbiased estimation fusion. *Proceedings of the 2nd International Conference on Information Fusion*, Sunnyvale, CA, 1999, 1054 – 1061.
- [64] 龙永锡, 赵宗贵. 机动目标的最优判决. 平滑滤波技术交流会会议录. 北京: 国防工业火控技术情报网, 1977.
- [65] 龙永锡, 赵宗贵. 机动目标的似然比判定滤波及其在 C2 系统中的应用. *电子学报*, 1985, 7(4).
- [66] Brendan P Rivers, Michael Puttre. The US Navy presents its battle plan for network-centric warfare. *The Journal of Electronic Defence* 2011.
- [67] 赵宗贵, 熊朝华. 信息融合概念、方法与应用. 北京: 国防工业出版社, 2012.11.



# 第 7 章 分布式目标分类识别

## 7.1 目标分类的概念与应用需求

目标分类在概念上是指对一个目标在某识别域内进行类别划分，即判定其属于该识别域内的哪个类别。在确定的识别域内，通常基于获得（观测或收集）的特征和属性（F&A）进行估计，获得目标所属的类别。文献[1]描述了美国国防部实验室联合理事会（JDL）给出的 4 个融合级别中的目标分类概念框架，如图 7.1 所示（含作者修正）。

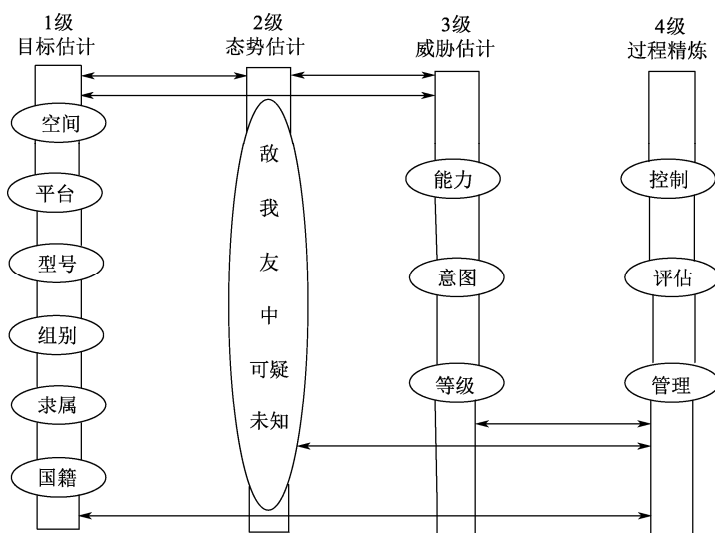


图 7.1 4 级信息融合中的目标分类

图 7.1 中，每个椭圆都表示战场感知目标的一个识别域，每个识别域都是该域可能包含的类别集合，即该域内的可能分类集合，该集合也称为该识别域的分类谱系。例如 1 级目标估计包含多个识别域，其中的空间域指目标所在空间分类（陆、海、空、天、电磁、Cyber 空间等），平台域指某确定空间分类下的可能平台类型（如空中目标类型：固定翼飞机、旋翼机、无人机、飞艇、气球等），型号域指某确定空间分类和平台分类之下的可能目标型号（如固定翼飞机型号：波音、F-16、F/A-18……）。2 级态势估计通过估计战场实体之间及其与环境要素之间的关系来识别实体的隶属方，故称为目标关系识别或目标身份识别域，其分类集合中包含敌、我、中、可疑、未知等类别。3 级威胁估计中的能力域主要指兵力单元或平台的作战能力，其分类集合包含平台的动力性能、携载、弹药、制导能力、干扰和抗干扰能力等；意图域指目标可能攻击的对象类别；等级域包含目标各种威胁行动和威胁程度，是基于能力、意图、时机及双方的对抗结果确定的。4 级过程精炼指通过控制、评估和管理实

现对前三级各域内的目标类别识别结果进行改善。我们注意到 1 级融合各识别域中的类别均属于目标自然（或内在）属性范畴，2 级融合识别域中的类别属于目标在战场上所充当的角色或身份范畴，而 3 级融合的 3 个识别域中的目标类别则是 1 级和 2 级识别结果与该目标状态和环境要素相结合产生的效能范畴。

在分布式目标分类/识别中，每个分布节点需要对哪一级融合的哪（几）个识别域的类别集合进行分类识别是由该节点所支撑的作战需求确定的，而作战对目标分类识别的需求依作战环节不同而异，如作战决策需要敌我分类识别、威胁意图和等级分类识别，而火力打击则需要对敌方目标的平台、型号和级别进行分类识别。此外，图 7.1 给出的各级信息融合目标分类识别之间的相互支撑关系也是值得我们注意的。

## 7.2 目标分类/识别方法

### 7.2.1 基于不确定性的目标分类/识别方法

不管何种目标分类/识别方法，都是通过对观测获得的目标特征或属性（F&A）来分析和识别目标类别，通常将特征称为目标的观测表示，把属性称为目标的内在表示。JDL 一级融合过程模型通常将自动分类技术与目标状态估计操作结合起来，实现目标的定位、识别与跟踪，即回答目标在哪里和目标是什么的问题<sup>[2, 3]</sup>。通常对识别结果赋予一个“系列编号”来表示所识别出来的具体对象或实体的类别（如飞机型号、级别，车辆类别型号等）。JDL 二级融合过程则基于获取的特征和属性采取某种模式识别过程来确定目标的身份类别，并按估计结果为该目标分配一个身份标记，多半是按目标型号与级别识别域的某个本体或分类法进行分配，该分配不是一个无条件过程，一个目标的识别很可能依赖于周边关系（Contextual），如一个对象是否属于“大目标”类，可能依赖于周围事物。我们注意到，对于二级融合中的目标身份域识别范畴来说，每个身份类别（敌，我，中，…）都是不可度量的，没有一个适用、统一的度量尺度。目标身份的非度量性质促进了表示、量化和处理身份不确定的各种方法的出现，包括概率统计方法，模糊集理论，可能性理论及神经网络方法等。文献[4]4.5.2 节描述了目标分类识别中所采用的 5 种不确定性融合方法：基于概率（经典概率、后验概率）的目标分类识别方法，基于隶属度的目标分类模糊识别推理方法，基于可信度的 D—S（Dempster—Shafer）证据合成方法，改进的 D—S 证据合成方法以及基于变权的综合推理方法。这 5 种方法采用不同的不确定性融合识别结构（见本书第 4 章 4.6 节），通过融合各局部对象分类的不确定性，生成全局对象综合分类识别结果及其不确定性表示。其中，最常见的是基于后验概率的贝叶斯综合推理方法和 D—S 证据合成推理方法，对分布式目标分类识别最有吸引力。贝叶斯推理对互不相容的局部分类命题集合进行操作，其中每个局部分类命题是基于相互独立的各局部测量产生的，通过贝叶斯法则对各局部分类命题进行概率合成，寻求使基于全局测量（各局部测量之并集）的后验概率达极大的全局分类命题。贝叶斯推理仅在已知的局部分类命题集合中选择全局最优分类，并不产生新的分类，并且要求局部分类

命题集合是完备的,即具有完整谱系。D—S 证据理论对互不相容的局部分类命题集合(称为基本命题集合)的幂集进行操作,幂集中的元素可以跨越多个基本命题;通过对不同观测手段获得的局部幂集元素的基本概率赋值(BPA)函数(又称 mass 函数)进行合成,产生作为各局部幂集元素交集的全局分类命题及 BPA 函数(对多命题 BPA 函数的合成产生的不确定性又称为可信度)。因此,D—S 证据合成推理方法能够面向不同层次的局部分类命题的合成,并能够产生基本分类命题集合之外的新的全局合成分类结果,这是对贝叶斯综合推理方法的重大改进,适用于对不同层次,不同谱系或谱系不完整的分类命题进行合成。然而,D—S 合成方法对无交集(不相容或冲突)的幂集元素的合成则无能为力。为此文献[5-9]提出了对 D—S 证据推理的几种改进方法,每种方法具有各自的优点和不足。笔者认为,Jousselme 等学者建立的证据距离函数<sup>[8]</sup>(即两个 BPA 函数之间的距离)适宜于作为权值参与证据之间的冲突性度量,实现包括冲突幂集元素的合成识别推理,具有较强的可应用性。有兴趣的读者可参考文献[4]中关于 Jousselme 的基于距离函数的证据冲突度量及应用案例。

### 7.2.2 目标分类/识别的基本步骤

数据融合与信息融合学界以及遥感界,在探索 and 开发基于特征和属性(F&A)的有效观测数据来估计与识别目标分类的自动方法上已经历很长的过程。当前,自动分类识别方法的研究和开发已成为目标/实体分类识别的主要目的。

从通用意义上说,基本的目标分类识别步骤如下:

- ① 通过传感器探测或侦察手段获取来自目标类别的测量信息,包括如前所述的目标内在属性和外在动态特征信息;
- ② 从观测信号/数据/图像等原始测量信息中提取目标的分类识别特征和属性证据;
- ③ 在多传感器探测或多信息源环境中,对原始测量信息或F&A进行时间和空间配准,包括确定时间和空间基准、估计与补偿时间误差和空间误差等;
- ④ 测量或F&A关联处理,产生源于同一目标的测量集合或F&A集合;
- ⑤ 对源于同一目标的测量集合或 F&A 集合中的各元素进行融合分类估计,按需求产生相应级别上的目标分类识别结果,包括分类命题及其概率(不确定性)。

对于传统集中式分类识别来说,各传感器(信息源)将原始观测信息或提取出的 F&A 信息传送到融合中心,融合中心集中实施②~⑤各处理步骤,产生最终的融合分类识别结论。对于分布式分类识别来说,各传感器或局部融合代理基于自身的观测信息,分别实施步骤②、④和⑤,产生目标分类识别的局部估计结果并将其传送到融合中心,融合中心实施步骤③、④、⑤,产生分类识别的全局估计结果,此时步骤③是指对各局部分类识别结果进行时间和空间配准,步骤④是指对各局部分类识别结果进行相关处理,而步骤⑤是指对源于同一目标的各局部分类识别结论进行判定级融合,以产生全局分类识别结果。

从上述目标分类识别步骤可以看出,从多源获取的原始观测信息或提取的 F&A 到产生目标分类识别结论并对其赋予一个对象标记是一个复杂的映射关系。并且,由于通常存在观测误差,以及对手尽力掺入虚假、干扰信息或采取伪装、隐蔽和欺骗(CC&D)等手段,导致识别过程

产生更多的复杂性,从而对于试图实现目标自动识别来说,几乎是不可能的。因此,在军事领域关于目标分类识别的研究,通常将自动目标识别、辅助识别或半自动识别方法统称为 ATR 方法或非合作目标识别(NCTR)方法,许多早期的文献<sup>[10-14]</sup>都描述了这些方法。关于 ATR 和目标分类识别这一广泛课题的最集中的来源是每年一度的光学摄影仪工程师学会(SPIE)防务会议。近期也有一些广泛领域的目标分类方法的一般研究成果,出现了针对确定性分类识别方法的各种概述性文章,但尚未涉及分类识别技术状态的顶层和原理性研究。

### 7.2.3 分布式目标分类识别方法的特点

与目标状态估计(定位与跟踪)相比,无论是集中式还是分布式目标分类识别,都具有如下特点:

(1) 依赖目标的静态特征与动态特征。目标的静态特征和动态特征都是目标分类识别不可或缺的因素,这是由于对目标的多层次分类识别的需求所产生的。静态特征通常指目标的自然(固有)属性,如平台类别型号、等级、尺寸、形状及目标辐射/反射信号特征等;动态特征通常指目标运动状态特征,如目标空间位置、速度、航向、机动特征等。这两类特征共同决定目标的各级自然属性分类和身份属性分类的识别结果,缺一不可。值得指出的是,目标之间及目标与战场环境和外部要素之间的关系属性即态势属性,态势属性也对目标分类识别起重要影响,态势属性能够对已有分类识别结果进行补充和修正,关系属性也同样具有静态(如隶属关系、协同关系、对抗关系等)和动态(转隶/动态编成,以及随态势变化出现的协同关系和对抗关系的变化等)两类特征。

(2) 信息重复计入问题。重复计入是指在目标分类识别的过程中,对同一信息计入两次或多次使用,产生的相关性会影响分类识别的准确性。该问题属于分布式融合信息图中某一上游共用信息节点信息为某后续信息节点多次使用的情况,在第4章中曾分析产生共用信息重复使用的原因,包括网络传输(多连接结构信息图)产生的共用节点,多传感器对关注区域(ROI)相互覆盖范围内目标测量的重复分发以及融合节点使用的先验信息等。具体到目标分类识别的过程中,产生信息重复使用的原因首先是一对传输证据的节点没有相互发送和接收分类识别命题的传输历程谱系信息或传输的谱系信息不完整,产生的数据混杂会导致识别中的信息重复使用;其次是相关的非统计独立测量信息必然产生信息重复使用;第三是表決分类判定系统采用的硬证据很可能未考虑其统计独立性状态而产生信息重复使用;第四是各证据采用的不确定性表示不一致,在混合不确定性统一变换中产生缝隙或覆盖引起证据信息的重复使用。

(3) 先验信息。目标分类识别不仅要不断获取新的测量或证据信息,而且还需要对先验信息进行比对(匹配和计算关联的不确定性),包括自身积累的和从其他来源获取的分类识别的谱系信息、指纹信息、统计分布信息及融合分类识别信息图及信息流程等。先验信息对于去除重用信息、证据信息的统一转换、分类命题的关联和识别选择具有决定性影响。

(4) 一致性和冲突性。目标分类识别的准确性和及时性依赖于所获得的分类识别信息量和分类识别知识量,差异性较小的一致性证据能完善、增加分类识别的信息量,但对于产生

分类识别结论的收敛性来说,可能需要较多的证据和较长的时间。冲突的证据含有较多的分类识别知识量,差异性(冲突性)越大的证据越能使分类识别过程更快收敛到正确的分类识别结论上。然而,当前许多逻辑或不确定性推理方法仅适用于目标分类的一致证据(又称兼容证据)的融合识别,而不适用于冲突证据的融合识别(如贝叶斯后验概率融合推理、D—S证据理论等)。因此,兼容一致证据和冲突证据的统一表示(如信息熵)以及基于冲突证据融合进行识别推理,正在成为当前识别领域的热门课题,目前已出现不少研究成果<sup>[8, 15, 16, 17]</sup>。

(5) 不确定性。在目标分类识别中,无论是实时获取的观测(证据)信息还是先验信息,都存在不确定性。不确定性信息的来源有三类,第一类是探测和侦察手段自身的可信性以及所获取信息的随机性(时间和位置无法准确预测)和模糊性(目标特征不清晰);第二类是目标识别特征的动态性和偶发性,目标的常规动态具有平稳性和可预测性,而非常规动态具有偶发性(如状态机动、偏离轨道等);第三类是来自非合作目标(NCT)为降低其被观测性的有意识行为,如隐身伪装、电磁干扰和欺骗行为,通常具有不可预测性和偶发性。不确定性有多种表示方法如经典概率、后验概率、基于基本概率赋值(BPA)的可信度和似真度、模糊隶属度等。需注意的是,由于命题的各种不确定性表示在概念和精度上存在差异,在进行统一转换时,可能会出现命题谱系裂隙或重叠,需进行相应补偿或去除。

(6) 分类识别信息空间。探测/侦察获取目标分类特征的信息空间包含三类:

- 合作信息空间:有意识配合分类识别行动的目标提供的识别特征信息空间。
- 非合作信息空间:只基于我方主动探测/侦察获取的非合作目标或未知身份目标(可能有CC&D等反制手段)的识别信息空间。
- 无意识合作信息空间:非合作目标或未知身份目标自身遂行业务活动(通信、探测、干扰等)的辐射信号或无意泄露的信息空间。

需要采用不同的技术手段获取每个分类识别信息空间中的目标特征信息,对合作信息空间通常采用IFFN或AIS等技术途径;对非合作信息空间,通常采用各种有源(主动)探测传感器;而对于无意识合作信息空间则采用无源(非主动)传感器。

## 7.2.4 目标类别与识别特征的关系

基于各信息源产生的目标识别特征对目标进行分类识别,需要分析各识别特征与目标类别之间的关系,这对于选择适宜的融合识别方法至关重要。我们以一个级别的对象类别,如平台或某一平台的型号和等级为例,说明其特征分类、证据分类与信息来源,如图7.2所示。

从图7.2可以看出,每类证据通常只支持一类特征的分类识别,基本上不相互涵盖,即三个状态特征分类集合是相互独立的。三类状态特征共同支持平台分类识别,每类状态特征在平台分类识别中所占权重不同,具体取决于相应的信息来源及其提供证据信息的可信度(概率)的综合。由于获取目标特征信息的探测传感器和侦察手段具有不同层次、不同功能且它们之间有一定程度的特征覆盖,因此在基于证据分类的平台分类识别中需要综合考虑多种手段提供的多层次证据及其可信度。

必须指出的是,基于观测证据直接识别平台类别是难以实现的,因为直接基于平台类别的各观测证据并不独立,此时各观测证据具有共用过程噪声,因此通常采用基于观测证据建

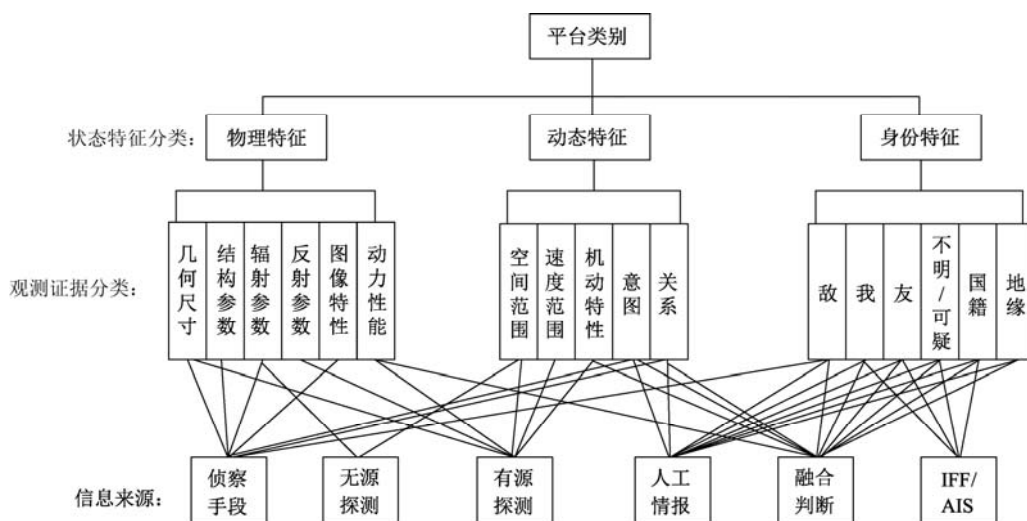


图 7.2 平台类别的特征分类、证据分类与信息来源

立各状态特征分类的联合特征分类器，再通过该联合特征分类与平台类别的条件概率，获取基于观测的平台分类识别结果<sup>[18]</sup>，如 7.3.1 节所述的“产生”型目标分类识别方法。在无法确定联合特征分类与平台类别关系时，通常情况下可以基于观测数据建立边缘分类器实现相应的特征分类，然后采用加权求和方法确定平台分类识别结果，如 7.3.2 节所述的“差异”型分类识别方法。

## 7.3 目标分类方法的基本类型

当前，可选用的目标分类识别方法可以划分为“产生”型、“差异”型和混合型三种<sup>[19]</sup>。下面分别描述这三种分类识别方法的概念和应用案例，可参考文献[22-24]以及文献[4]4.5 节。

### 7.3.1 “产生”型目标分类识别方法

“产生”型目标分类识别方法在概念上指由证据直接产生识别结果，因此要在获得的证据（特征和属性 F&A）与要确定的识别分类之间建立某种函数关系表达式，如对于空中固定翼飞机平台类别，需要建立平台类别（民航机、轰炸机、侦察机、战斗机等）与对其提供支撑的证据之间的函数关系，而身份类别可直接通过人工情报或识别系统（IFF/AIS）获得。“产生”型目标分类识别方法的一种函数形式是采用条件似然函数  $P(\text{特征/类别}) = P(Y/X)$  表示获取的观测特征  $Y$  与分类识别命题  $X$  之间的关系，并且该目标识别命题具有一个先验概率  $P(X)$ 。该函数关系也可表示为  $P(X)$  和  $P(X/Y)$ ，即目标类别的先验概率和基于观测特征的后验概率。“产生”型分类识别采用的技术包括基于模型的识别方法、高斯混合密度及贝叶斯因果网络等，其中的关键在于具有证据与类别之间关系的详细知识，如条件概率分布和诸证据之间统计独立性等。“产生”型目标分类识别方法的优点和不足见表 7.1 上部。

表 7.1 两类型目标分类识别方法的特征

方 法	优 点	缺 点
“产生”型目标分类识别	能引入先验知识，不需要大的训练集，容许合成输入	建模不经济，无法采用通用优化准则，依赖专业领域知识，只面向已知假设命题
“差异”型目标分类识别	具有更快的预测速度，能更精确预测	只针对具体任务，训练时间长，不容易处理合成性命题

下面给出一个应用贝叶斯推理的“产生”型分类识别案例。该识别方法的目标身份分类识别结构（识别过程见文献[4]）如图 7.3 所示。其中提供证据的三类信息源是 IFF、ESM 传感器和有源雷达；提供的证据分别为  $E_1$ 、 $E_2$  和  $E_3$ ；分类识别的命题是目标身份  $ID_1$ 、 $ID_2$ 、 $ID_3$  分别表示目标身份敌、我、中；该图所示识别过程采用的中间分类特征是目标的  $n$  种可能机型  $J_1, \dots, J_n$ 。

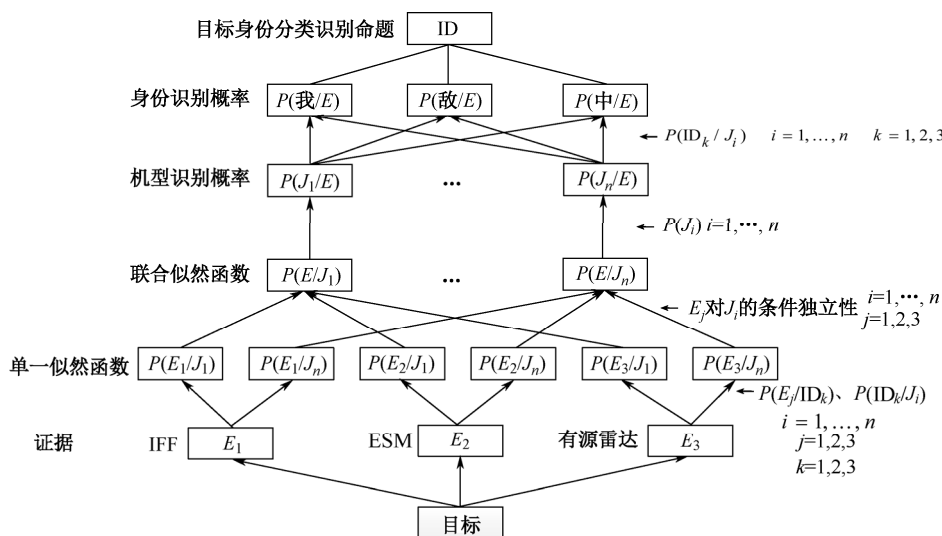


图 7.3 基于贝叶斯推理的目标身份识别结构

图 7.3 中各有向边线表示采用的贝叶斯因果推理。其中右部各“ $\leftarrow$ ”是指左侧的各分类识别步骤所需要的先验知识。图中所示的贝叶斯因果网络自下向上，最底层是传感器（信息源）节点，提供来自该目标的三类识别证据；最顶层目标身份分类识别节点是结果节点，通过门限判断产生选择的识别命题；中间四层节点框中是相应中间级别参数的条件识别概率。

### 7.3.2 “差异”型目标分类识别方法

“差异”型目标分类识别方法主要针对分类识别系统输入具有较大差异的多类证据  $Y$ ，它们分别支持分类识别命题的不同状态特征，而这些不同状态特征具有很弱的关联性，故只能作为分类识别命题的并列特征。在这种情况下，无法基于观测证据  $Y$  建立“产生”型目标分类识别命题  $X$  的关系函数  $P(X/Y)$ ，只能基于有较大差异的每类证据  $Y_i$ ，构造或训练产生其与支持的命题并列特征  $X_i$  之间的关系，通过学习和训练，形成  $P(X_i/Y_i)$  统计估计模型。然后再学习和训练产生各类证据识别结果的合成权值，加权合成基于多类证据的分类识别结果。逻辑回归、神经网络、多差异分类器、支持向量机等都属于“差异”型目标分类识别方

法。“差异”型目标分类识别方法的一个技术实现途径是首先对非关联或弱关联的每类证据构造相应的多个单一分类器，然后再对各单一分类器的识别结果进行权重训练合成，以实现目标分类的综合识别，这将大大提高分类识别的精度。“差异”型目标分类识别方法的优点和不足见表 7.1 下部。下面给出“差异”型目标分类识别方法对空中平台的识别分类器结构（识别过程见文献[4]4.7.4 节），如图 7.4 所示。

图 7.4 中，分类器 1 是基于观测信号的分类器，观测信号为射频、脉间和脉宽，来自 ESM 传感器提供的证据；分类器 2 是基于目标的分类器，目标参数为速度、高度和雷达回波截面积，来自有源雷达数据处理；分类器 3 是基于态势信息的分类器，态势参数为目标航迹、活动区域和机场位置，来自雷达信息统计累积和先验信息。三个单一分类器的识别结果是各自识别参数（证据）与各目标分类  $C_j$  ( $j=1, \dots, n$ ) 的局部关联信度  $m_{i_1}, \dots, m_{i_n}$  ( $i=1, 2, 3$ )。综合分类器对三个单一分类器的识别结果进行综合，基于每个单一分类器产生的证据参数与目标分类  $C_j$  的局部关联信度  $m_{i_1}, \dots, m_{i_n}$ ，计算所有传感器测量和态势/先验信息与目标分类  $C_j$  的综合关联信度  $m_1, \dots, m_n$ ，其中最大并超过预设门限的关联信度对应的目标分类  $C_k$  即为分类识别结果。

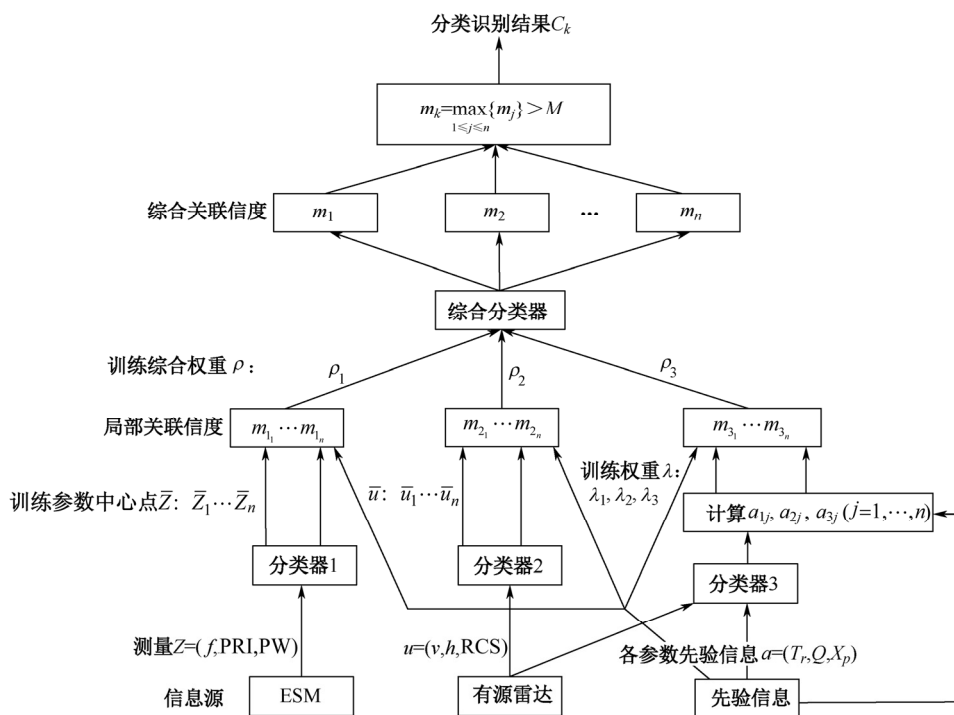


图 7.4 “差异”型目标分类识别方法对空中平台的识别分类器结构

值得注意的是，先验信息在各局部分类器和综合分类器的构建和识别中具有重要作用，包括在计算各局部关联信度时，测量态势参数与各识别命题的关联基准、在分类器 3 态势关联中对三类态势参数与分类识别命题关联信度的计算以及对三个局部分类器的综合权重的训练生成等，均需要假设各识别命题的先验信息。

### 7.3.3 混合型目标分类识别方法

目标分类识别的第三种类型是混合型，它是针对可能产生未知分类的识别命题而提出



的。上述“产生”型和“差异”型目标分类识别方法皆假设已预先知悉目标的可能分类，即已设定了目标分类谱系，识别结果也仅限于谱系中某一分类。我们知道，随着科学技术的发展，新的武器装备平台不断出现，旧的武器装备平台陆续被淘汰，这必然会导致战场目标（平台）分类谱系不断变化，因此在战场上很可能出现超出预设目标分类谱系的新类别，其在特征上与已有分类可能有重大差别。因此需要建立一种新的目标分类识别方法，在对预设谱系中的目标分类进行识别的同时，还要能够识别并建立超出分类谱系的新类别。之所以将这种新的目标分类识别方法称为混合型，是因为其识别的分类命题既包含已有预设命题，又包含预设命题的任意组合及其交集产生的新命题。更加值得注意的是识别的分类命题还可能产生于各类信息源的观测结果中，这是由于具有重大改进或新型的传感器（信息源）能够观测并产生新的目标类别。混合型目标分类识别方法具有下述特征：

证据与类别统一表示。将单一信息源提供的识别证据或多信息源提供的综合识别证据视为分类识别命题，这是由于分类识别命题的多层次、多类别（见文献[4]第4章）以及信息源的多手段、多介质产生的观测证据与目标分类具有很大程度的耦合性和关联性产生的，如基于无源ESM传感器检测信号能产生目标辐射源类别和平台型号，有源雷达探测数据能产生大目标、小目标，甚至轰炸机、侦察机、战斗机的识别证据，而人工情报很可能直接提供目标某些层次上的目标分类识别结果。

传统分类识别谱系的扩展。包括三个方面：①由一个层次的完备谱系扩展为多层次分类命题的混合谱系，从而产生多个单一分类识别谱系的混合分类谱系；②新的混合分类谱系中的元素可以弱相容、不相容（冲突），并且可能是不完备的；③混合分类谱系中所含有的各谱系之间在层次上、相容性和完备性方面能够相互转换，以统一计算不同单一谱系分类命题的概率（不确定性）。

目标分类融合识别方法要能够兼容一致性证据、弱相容或不相容（冲突）证据，以克服由于传统分类谱系不完整、信息源不可靠及噪声干扰产生的分类识别错误，如Zadeh的一个著名的嫌犯识别问题就是由于干扰产生的识别错误<sup>[21]</sup>。

在混合型目标分类的多源融合识别方法中，两个或两个以上证据既可以共同支持某类型的同一状态特征（子类别），也可以分别支持某类别的不同独立状态特征（子类别）。

支持混合型目标分类识别的不确定性方法有：

#### ① 模糊推理方法。

在证据 $A_1, \dots, A_n$ 共同支持同一分类特征，产生新分类 $A = \bigcap_{i=1}^n A_i \neq \emptyset$ ，以及 $A_1, \dots, A_n$ 相互冲突（即分别支持某分类的不同独立特征），产生新分类 $A = \bigcup_{i=1}^n A_i$ 的情况下，采用隶属度的两种合成形式产生合成分类的隶属度为

$$C(A) = \mu_{\Theta}(A) = \begin{cases} \inf_{x \in \{A_i\}_{i=1}^n} \{\mu_{A_i}(x)\} & A = \bigcap_{i=1}^n A_i \neq \emptyset \\ \sup_{x \in \{A_i\}_{i=1}^n} \{\mu_{A_i}(x)\}, & A = \bigcup_{i=1}^n A_i \end{cases} \quad (7.1)$$

式（7.1）右端分别被称为合取和析取。

## ② 修正的 D—S 证据合成方法。

基于 Jousselme 等人提出的基于证据距离函数产生的证据冲突度量形式<sup>[8]</sup>,  $n$  个证据  $E = (A_1, \dots, A_n)$  的合成分类识别命题  $A$  的信度为

$$C(A) = P(A) + k\alpha(E)q(A) \quad (7.2)$$

其中

$$P(A) = \sum_{A=\bigcap_{i=1}^n A_i \neq \emptyset, A_i \in E} m_i(A_1) \cdots m_n(A_n), \quad k = \sum_{\bigcap_{i=1}^n A_i = \emptyset, A_i \in E} m_i(A_1) \cdots m_n(A_n) \quad (7.3)$$

分别为基于  $n$  个相容证据产生的合成分类  $A$  的信度和  $n$  个证据的冲突信度, 而

$$\alpha(E) = e^{-C_{glo}(E)} \quad (7.4)$$

是将冲突信度  $k$  分配给合成命题  $A$  的有效分配系数, 其中  $C_{glo}(E)$  是证据集合  $E$  的全局冲突信度, 是基于 Jousselme 距离获得的,  $q(A)$  为合成分类  $A$  的平均质量 (mass) 函数。

值得指出的是, 共同支持某类识别命题的同一状态特征的证据实际上是指相容 (一致) 证据, 而分别支持某类识别命题的独立状态特征的证据是指弱相容或冲突证据, 上述两种方法能实现对这两类证据的合成, 产生不同于预先各假设分类的新的合成分类识别结果。

## 7.4 多级目标分类识别结构

在分布式战场感知系统中, 网络连接的各级融合节点都具有相应级别的目标分类识别功能。每级节点的目标分类识别产品类别取决于其接收的识别特征信息级别和与该节点耦合的作战活动需求。由图 7.1 可以看出, 战场目标分类包含多个层次、多个类别, 它们依赖于各类信息源 (传感器探测、技术和人工侦察手段, 以及识别系统) 提供的识别证据。识别证据在介质、内容和格式上可能五花八门, 但经过预处理之后, 大体可以分为测量信号、目标数据、目标特征和局部判定分类 4 级。分布式目标分类识别结构既体现了信息源提供证据的级别, 又体现了目标分类融合识别的级别。图 7.5 给出了目标 4 级融合分类识别结构。

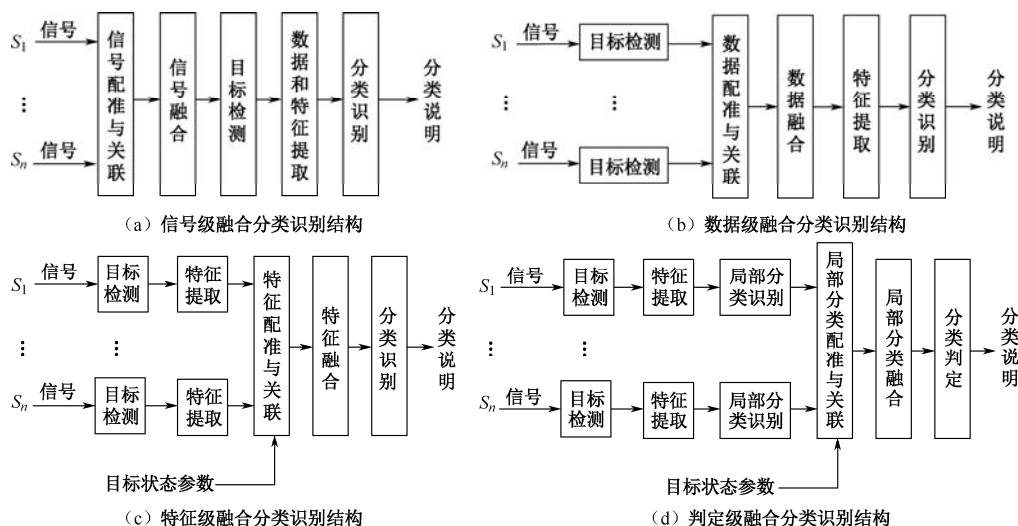


图 7.5 目标 4 级融合分类识别结构

图 7.5 给出的目标融合分类识别结构主要展现了融合识别出现的级别，每个结构在融合识别之前都要对相应级别的多源信息进行时间空间信息谱系配准和关联，然后对融合后的联合信息进行分类识别操作，直至产生基于多元信息的目标分类说明。

在信号级融合分类识别结构中，融合节点对各传感器测量信号进行融合，再从融合信号中提取具有丰富信息的目标数据和特征，最终获得具有最高准确度的目标分类识别结果。该结构主要针对弱信号目标（小目标、隐身目标）的检测识别。在分布式系统中，各传感器要向低层融合节点传送含有大量原始测量信号的高速率视频数据，因此需要极大的网络带宽，并且通常会产生时间延误和一定程度的传输误差。

在数据级融合分类识别结构中，各传感器节点基于自身测量信号进行目标检测，融合节点对各传感器检测数据与来自其他网络节点的目标数据进行融合，再从融合数据中提取目标特征，进行分类识别，最终获得目标分类说明。该结构是当前检测和识别常规目标的一个通用结构，尽管各传感器向融合节点传送的信息相对测量信号有一定压缩，但传输数据量仍不可小觑，仍需较大网络带宽，并有一定时间延误和传输误差。

在特征级融合分类识别结构中，基于信号的目标检测和特征提取都在各自传感器节点上自主进行，融合节点对来自各传感器的识别特征与来自其他网络节点的目标特征参数进行融合，然后进行分类识别，产生目标分类说明。该结构也是当前具有一定自主能力的传感器与网络节点提供的目标特征进行融合识别的一个通用结构。尽管特征提取和融合过程中会产生测量信息损失，从而出现分类识别偏差，但该结构大大压缩了网络节点间的传输信息量，故仅占用较低通信带宽，并且随着传感器智能的提升，其提取的局部分类特征准确度提高，因此能在一定程度上满足目标分类识别精确度的要求。

在判定级融合分类识别结构中，传感器节点自主进行的目标分类识别处理一直持续到产生目标局部分类识别结果，融合节点对来自各传感器或其他节点的目标局部分类识别结果进行判定级融合，并基于门限判定产生目标的全局分类识别说明。由于判定级融合分类结构仅传送局部分类识别信息，故传输占用的网络带宽最小。但该结构在各传感器的一系列自主分类处理中会损失较多的有效原始测量信息，因此产生的各局部分类会出现较大偏差，导致最终的全局判定级融合分类识别结果出现偏差或错误。此外，当各局部分类识别结果相容性较弱或出现冲突时，融合中心难以实现判定级融合，此时通常要追溯到特征级甚至数据级的分类识别结果，寻找相容证据，或者等待后续传感器测量或其他节点证据的到来，继续实施目标分类识别操作。

在工程实践中，往往会出现各传感器和其他节点提供的目标识别证据处于不同的级别上，也可能是不同级别证据的混合。此时，为了在目标分类识别中兼容多源多级识别证据，融合节点可以采用如图 7.6 所示的多级混合分类识别结构，其中最终输出的局部分类说明是指基于证据来源进行的部分级别（一、二或三级）证据融合分类识别结果，而全局分类说明是指具有完整的四级证据产生的全局融合分类识别结果。

在分布式信息融合系统中，某一节点可能只需进行某一级别的目标分类操作即能满足相应级别的应用需求，此时可以采用“信息共享策略”（Information Sharing Strategies, ISS）确定节点之间信息的收发关系，包括通信频段、传输协议、信息内容和格式，以使某节点能够

接收到同一目标分类级别的识别证据, 达成对该目标的分类识别。ISS 是网络结构和信息结构的重要组成部分, 它涉及合作的多代理网络在 multi 资源约束下的全局信息效用达极大的传输路径分配问题, 详见第 4 章。

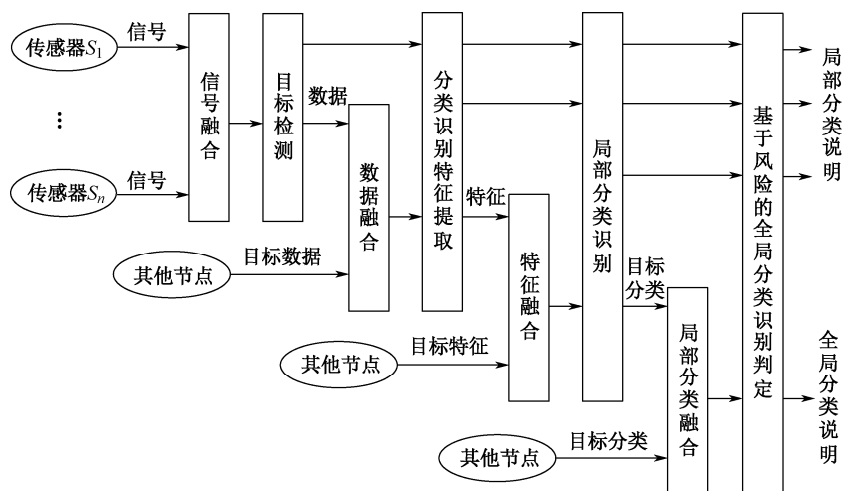


图 7.6 目标分类识别的多级混合结构

## 7.5 分布式目标分类识别中的新问题

随着传感器类型和数量的急剧增加, 分布式目标跟踪与分类识别正在成为网络中心战的重要研究领域<sup>[25, 26]</sup>。与分布式目标跟踪有关的问题类似<sup>[27]</sup>, 分布式目标分类识别也包含各节点之间数据级和判定级的交互及其对融合结果产生的影响。在信息融合系统中, 任一级别的融合节点都要考虑共用基准、信息关联和状态估计功能, 如图 7.7 所示。

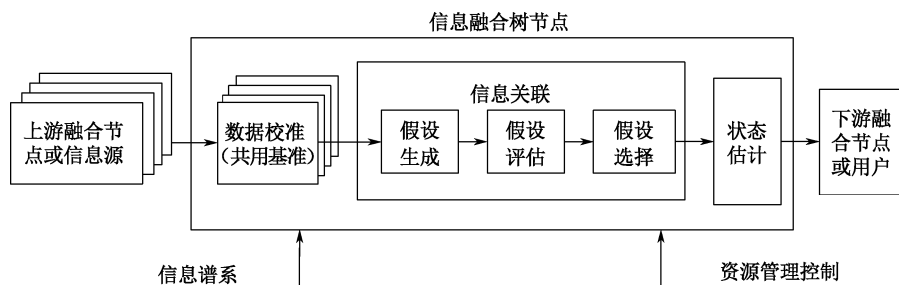


图 7.7 各信息融合节点的通用功能

分布式网络不同位置的节点的融合功能和级别可能不同, 因此图 7.7 中相关信息的内涵可能不同。在分布式感知网络 (如无线传感器网络 WSN) 中, 任一节点可能仅具有对网络其他节点功能和能力的有限认知, 通常假设任一节点仅知道其邻近节点而不知道远距离节点的具体信息。从图 7.7 可以看出, 某一节点的功能与其上下游节点功能紧密相连, 因此该节点需要知道与其通信的上下游节点的具体信息才能达成相应的融合功能。这样一来, 在网络节点之间的信息交互中, 发送节点除发送任务消息外, 还要向接收节点发送附加的元数据,

以使接收节点的操作获得充分的信息。当然,接收节点要能够处理接收消息中的附加元数据并将其融入功能处理中。融合学界称这个元数据为“谱系”,其定义为接收节点所需要的信息。在分布式目标分类识别中,某节点的信息谱系通常指下游节点的分类识别所需要的可能识别命题的完备集合。在分布式融合信息图中,其信息谱系还包含共用节点信息的传输路径,以使下游节点能够识别共用上游节点和重用信息。

分布式目标分类识别新出现的四个问题分别称为显式重复计算、隐式重复计算(统计依赖情况)、传统系统的硬说明问题以及混合不确定性表示问题。分布式目标分类识别还有一些其他问题,但这四个问题比较典型,在应用环境中还可能出现这些典型情况的组合案例。下面我们对这四个问题分别进行描述,但每个模型均不含有融合节点向其输入(贡献)信息节点的反馈,因为反馈会增加层次之间谱系操作的复杂性。

### 7.5.1 显式重复计算

第4章描述了已知上游共用节点信息为某一下游节点重复使用会产生信息相关,从而导致融合误差协方差增长,该问题在目标分类识别中以显式重复计算的称谓出现。所不同的是,显式重复计算中的共用节点信息既包含上游共用节点产生的目标分类识别消息,又包含附加信息,如消息传输路径、分类谱系等。附加信息对于准确得知信息传输路径及路径上各节点对上游共用节点信息的重复使用状况是不可或缺的。图7.8给出了一个显式重复计算的信息图和产生过程。

从图7.8(a)可以看出,节点 $N_1$ 的上游节点 $L$ 与下游节点 $L_1$ 之间有2条传输路径,其中一条经节点 $N_2$ ;  $L$ 与 $L_2$ 之间有3条传输路径,其中2条经节点 $N_2$ 。故 $L$ 点的分类识别信息和附加信息被 $L_1$ 点融合计算使用2次,被 $L_2$ 点使用3次。

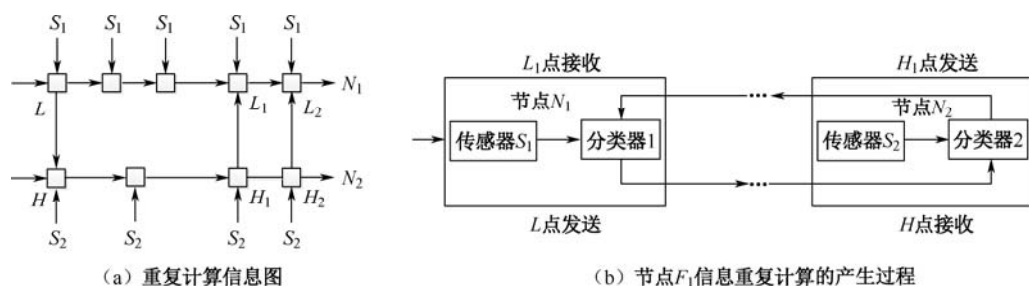


图 7.8 显式重复计算信息图和产生过程

图7.8(b)描述了节点 $N_1$ 和 $N_2$ 对 $L$ 点信息的循环发送—接收过程,即节点 $N_1$ 的下游点 $L_1$ 对自上游节点 $L$ 的识别信息的两次获取过程;其中一次是节点 $N_1$ 的自身传递,另一次是经节点 $N_2$ 传送,其信息包含在 $N_2$ 节点分类器2的分类识别信息中。

该重复计算也被称为“数据混杂”、“传闻扩散”或“自中毒”,因其会增大目标分类识别误差,导致分类识别错误。称为“显式的”是由于只要通过附加信息中的谱系标签和传输路径即可知道重复使用的上游共用节点和信息内容,这对变更信息图为单连接结构或采用适宜的分类识别算法以避免或克服信息重用产生的误差至关重要。

### 7.5.2 隐式重复计算

隐式重复计算是由被融合的信息之间的统计依赖性（非独立性）产生的，因为基于统计学的分类器或识别融合运算通常假设输入的共用信息具有统计独立性。例如基于后验概率的贝叶斯方法假设共享信息具有统计独立性，可以将联合证据的条件概率密度（似然函数）表示为各证据条件的似然函数之积，否则计算联合证据似然函数存在巨大困难，会导致人们寻找其他方法。在统计独立性不满足或难以准确得知的情下，仍采用基于证据统计独立的分类识别方法会产生分类识别误差，导致分类识别错误。该问题被称为隐式重复计算是由于各感知证据存在共用信息产生的信息冗余且分类识别运算之间的关系是隐含的，无法分离出相关的共用信息，图 7.9 给出了这一思想。




图 7.9 隐式重复计算思想

由图 7.9 可以看出，从每个传感器测量或信息源收集的证据中提取分类特征和属性（F&A，这里称为特征  $F$ ），然后每个单一分类器基于输入的特征进行分类识别，产生目标分类识别说明，包括识别标识 ID 及作为其分类识别统计量的后验概率  $P(\text{ID}|F)$ ，并将它们一起发送给融合中心。从该图中我们注意到，从两个传感器提取的特征中有一个共用特征  $F_1$ ，它为两个单一分类器共同使用，导致两个单一分类器的分类识别说明是相关的。这样一来，融合节点对两单一分类器的识别说明采用贝叶斯方法进行融合时，并不知道这两个单一分类识别说明是否采用了共用特征  $F_1$ ，却错误地假设这两个输入的单一分类识别说明具有统计独立性，这就两次计算了特征  $F_1$  对融合分类识别的影响。从传输附加信息中的谱系标签就能够回溯看出融合分类识别说明依赖于哪些单一分类器和哪些分类特征，并能清楚获知分类特征重复使用的情况，但是由于通信带宽的限制，通常无法回溯知晓这一点，即无法准确知晓共用特征  $F_1$ ，或者说共用特征  $F_1$  是隐含的。

### 7.5.3 采用硬说明的传统融合识别系统

该问题是指分布式网络连接的是“传统”系统分类识别节点（预先已构建好，当时尚未考虑入网需求），可能出现两种情况：①各传统分类识别节点的 ID 分类器是“硬”分类器，其产生的是一个没有确认度量统计量（如概率、可信度等）的分类识别标记，实际上就是一个“表决”结果产生的一个确定（无条件）类别；②该传统识别节点分类器产生的 ID 确认度量统计量与其接入的感知网络其他节点分类器采用的确认度量统计量不一致。

第一种情况是有代表性的情况，目前许多传感器—分类器都只产生“硬”ID 说明，而缺少对该 ID 说明的确认度量，即缺少对表决结果的有效性说明。对多个“硬”ID 说明的融合分类识别通常采取表决策策略，如图 7.10 所示。




图 7.10 采用“硬”ID 说明的传统识别系统

图 7.10 中的融合识别节点采用对各局部硬分类 ID 的判定级融合方法，即基于表决的融合识别策略，这与第 5 章 5.3 节基于计数表决规则的 WSN 检测方法类似，但这里是针对识别多命题分类，即多元假设检验问题，可采用针对某一分类命题的过半数或多数表决策略。与 5.3 节一样，这里采用表决融合策略同样明显地忽略了各局部分类 ID 的相关性，如图 7.10 中两个分类器均依赖共用分类特征  $F_1$  的情况。如果采用有代表性应用的训练数据，确定输入的各分类 ID 及其对融合分类 ID 的影响，就能够对参与表决的各分类 ID 赋予不同权重，从而产生满意的融合表决结果，当然这些权重也要包含在附加谱系信息中，并且是可动态变化的。

对于第二种情况，需要将接入的传统识别节点的分类 ID 确认统计度量变换为与接入的网络各节点的分类识别 ID 确认统计度量一致的形式，以在归一化的不确定空间中进行分类融合操作，这与混合不确定性表示的分类融合方法类似。

#### 7.5.4 混合不确定性表示

在各网络节点的分类识别结果采用不同的确认表示形式的情况下，如图 7.11 中不确定类型 1 和 2，他们可能是概率统计表示或证据信度表示。此时融合分类节点可能将各局部分类的各种不同确认表示转换为统一表示形式，如从证据信度形式转换为概率形式，并对转换后的不确定性进行归一化处理，然后使用贝叶斯融合过程进行分类识别。我们注意到，谱系标签还应包含每个分类器评估模式使用的不确定性类型，以使融合节点能够确定不确定性共用基准并进行各局部不确定性类型的统一转换。此外，转换后的全局不确定性类型和分类谱系与各局部不确定性类型和分类谱系之间可能存在缝隙（遗漏）或覆盖，需要进行补偿或去除。还需要注意的是，要充分理解具有统计或其他变型的不确定性表示并将它们适宜地包含在该融合模式中。




图 7.11 采用混合不确定性表示的融合分类器

现实的分类系统或分类网络，可能采用多个传感器分类器作为全局融合分类的输入节点，其往往归结到某个共享（集中式）或分布式框架，或二者的组合之中。这使得接收节点的融合依赖于整个分类系统的结构，并且分类谱系标签要包含所有可能的影响因素，其中某

些特定标签元素可能是空的，这就大大增加了融合分类运算的综合复杂性。

## 7.6 基于局部分类器的全局融合识别

本节主要研究对各局部分类器的识别结果进行全局融合识别的方法，又称为分类器组合方法。本节介绍的研究成果来自文献[28-30]。传统分类器最优组合技术来源于文献[31]所提出的一个分类学方法，其中，分类器最优组合的两个主要度量指标是效率和精度。多分类器系统中的效率可以通过把系统调节到最适宜的工作状态，即在应用中的任意给定瞬间，系统所需要的计算能力可以使用最小强度的分类器来达成。在多分类器系统中，精度的改善可以通过对不同的传感器数据或提取的特征、有一定差异的算法及对多种提供某些特定裨益的方法进行选择来实现。改善分类识别精度的这个宽泛的提法旨在利用相异性，即基于数据/特征、算法、方法的差异性来改善分类识别精度，尽管分类学中的相异性还是一个有争议的题目。无论是共享（集中）式还是分布式目标分类系统，都要对来自多节点的局部分类器的不同识别结果进行组合。

### 7.6.1 多分类器融合技术的分类

文献[31]中提供了关于多局部分类器全局融合技术的一个分类方法，如图 7.12 所示。

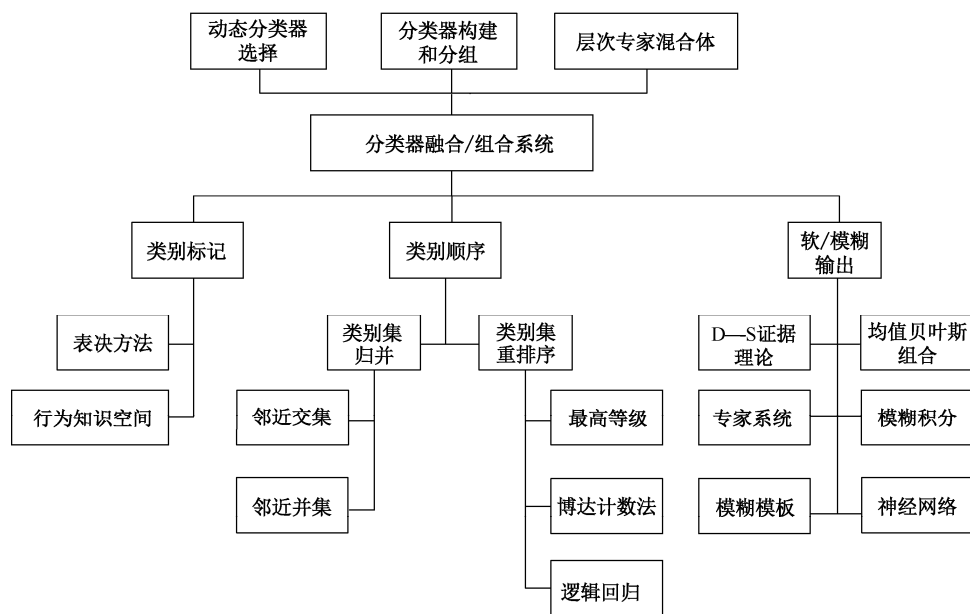


图 7.12 多局部分类器全局融合技术的分类

图 7.12 顶部三框中的内容是构建分类器组合系统的条件，下面三框中的内容是分类器组合系统的分类识别结果，向下引伸出的各框是相应采用的各项技术。

我们注意到，多分类器全局融合（许多文献中称为“分类器组合”）技术的选择依赖于各分类器共享（共用）的信息类型。若各局部分类器仅提供硬（无条件）标记或判定，则一个典型的全局融合方法就是表决方法（要注意的是，除了过半数和基于多数的方法<sup>[32]</sup>之外，还有许多不同的表决策略）。图 7.12 中提出了软/模糊输出的概念，其中任一分类器提供的类



别标记受不确定性数据限定，如使用分类器试验/校准所得到的条件概率就是一个适宜的限定量，此时，融合或组合过程就可以开发统计运算中的限定概率信息。

### 7.6.2 分类器组合方法

选择用于组合各分类器识别结果的方法受各种因素的影响，倘若只有分类“标记”是可用的，即各分类器给出的识别结果只是一个无条件的类别（如目标的类别、型号或等级，见文献[4]第4章），而没有其他数量限制（如与分类标记伴随的不确定性数量或等级），则这样的分类标记称为一个“硬”说明。此时可利用各种表决方法对分类标记或硬说明进行组合<sup>[32]</sup>。如果各分类器能够连续输出其分类识别标记及所希望的后验概率（称为“软”说明），则可能采取多种组合策略，此时我们假设所有有贡献的分类器使用一个一致的、基于概率的不确定性表示形式（见前文 7.5.4 节所述）。除概率外，不确定性的一致表示形式还有模糊隶属度、证据理论形式和可能性理论形式，每种形式都能够用于组合各分类器的识别结果（如证据理论的 Dempster 组合规则）。当然，各种不确定性表示形式的组合方法都要求各分类器提供的分类识别结果在关系上具有语义一致性，否则需进行某种类型的语义或相关数学变换，包括在分类谱系和粒度上的变换。当谱系出现冲突时，组合的后验概率会没有意义。

两个基本的多分类器组合方法是<sup>[29]</sup>：基于所有分类器提供的共用数据的组合方法，它主要出现在多个同类分类器（采用同类信息源的分类器）组合的情况，故称为“算法组合方法”，它对组合结果的影响来自各分类器采用分类算法的差异；另一个方法是针对每个分类器从不同信息源接收特定数据（如一个分布式系统）产生的分类识别结果进行组合，也称为异类分类器组合方法。显然，人们主要关注的是第二种情况，即异类分类器组合模式，包括产生式规则、求和规则、极小规则、极大规则、中值规则和多数表决规则等。

为了说明这些组合规则的特征，我们以产生式规则为例<sup>[33]</sup>，考察一些异类分类器组合算法。设第  $i$  个分类器采用特定测量向量  $x_i$ ，目标分类识别结果（类别或型号）为  $\omega_i$ ，其先验概率为  $P(\omega_i)$ ， $i=1,2,\dots,R$ 。则贝叶斯组合分类（即基于多局部分类器的全局分类）问题就是给出测量向量  $\mathbf{Z} = (x_1, x_2, \dots, x_R)^T$ ，确定目标的融合分类。

设融合分类标记为  $\omega_f$ ，在极大后验（MAP）准则下，

$$P(\omega_f | x_1, \dots, x_R) = \max_{\omega_k} [P(\omega_k | x_1, \dots, x_R)] \quad (7.5)$$

我们注意到，按式（7.5）产生的融合分类  $\omega_f$  只是诸  $\omega_i$  中的一个，并不会产生一个新的分类说明，并且基于各分类器产生的估计对象的 MAP 分类只是一个离散的判定过程。式（7.5）的求解需要知道测量向量  $\mathbf{Z}$  各分量之间即各信息源之间的相互依赖关系，也就是基于各识别结果的条件概率知识  $P(x_1, \dots, x_k | \omega_k)$ 。如果假设在识别分类  $\omega_k$  下，各信息源是条件独立的，即

$$P(x_1, \dots, x_R | \omega_k) = \prod_{i=1}^R P(x_i | \omega_k) \quad (7.6)$$

于是由贝叶斯公式并利用式（7.6），式（7.5）左端成为

$$\begin{aligned}
 P(\omega_f | x_1, \dots, x_R) &= P(x_1, \dots, x_R | \omega_f) P(\omega_f) / P(x_1, \dots, x_R) \\
 &= P(\omega_f) \prod_{i=1}^R P(x_i | \omega_f) / P(Z)
 \end{aligned}$$

同样，式 (7.5) 右端成为

$$\max_{\omega_k} [P(\omega_k | x_1, \dots, x_R)] = \max_{\omega_k} \left[ P(\omega_k) \prod_{i=1}^R P(x_i | \omega_k) / P(Z) \right]$$

式 (7.5) 变成：

$$P(\omega_f) \prod_{i=1}^R P(x_i | \omega_f) = \max_{\omega_k} P(\omega_k) \prod_{i=1}^R P(x_i | \omega_k) \quad (7.7)$$

从每个有贡献的局部分类器识别结果的后验概率出发，基于式 (7.7) 获得极大后验组合分类识别结果的过程如下所述：

注意  $P(x_i | \omega_f) = P(\omega_f | x_i) P(x_i) / P(\omega_f)$ ，于是式 (7.7) 左端成为

$$\begin{aligned}
 P(\omega_f) \prod_{i=1}^R P(x_i | \omega_f) &= P(\omega_f) \prod_{i=1}^R [P(\omega_f | x_i) P(x_i) / P(\omega_f)] \\
 &= P(\omega_f)^{-(R-1)} \prod_{i=1}^R [P(\omega_f | x_i) P(x_i)]
 \end{aligned}$$

同理式 (7.7) 右端成为

$$\max_{\omega_k} P(\omega_k) \prod_{i=1}^R P(x_i | \omega_k) = \max_{\omega_k} P(\omega_k)^{-(R-1)} \left[ \prod_{i=1}^R P(\omega_k | x_i) P(x_i) \right]$$

在各分类传感器采用等先验概率测量向量的情况下，即  $P(x_i) = P(x)$ ， $i=1, \dots, R$ ，式 (7.7) 变成：

$$P^{-(R-1)}(\omega_f) \prod_{i=1}^R P(\omega_f | x_i) = \max_{\omega_k} P^{-(R-1)}(\omega_k) \prod_{i=1}^R P(\omega_k | x_i) \quad (7.8)$$

式 (7.8) 称为分类器组合的“产生式规则”，即由各分类器的分类识别结果  $\omega_k$  ( $k=1, \dots, R$ ) 产生极大后验准则下的融合分类识别  $\omega_f$ 。从式 (7.8) 中的分母可知，产生式规则能够去除共用先验信息  $P(\omega_k)$  产生的  $R-1$  次重复计算，但需要假设右端的每个局部贝叶斯分类器所使用的观测（证据）具有条件独立性。在许多情况下，由于各局部分类器的观测  $x_1, \dots, x_R$  相互具有依赖性而无法建模（如 7.5 节所述），此时可采用 naive 贝叶斯组合规则，由于该规则是对贝叶斯意义的重大简化，很可能会出现这样的情况：具有很小后验概率的某个单一恶劣分类器说明会抑制其他正确或有吸引力的分类器说明，并且该组合规则没有解决重复计算问题。

异类分类器组合求和规则模式可进行与上述产生式规则类似的开发，它可以包含不同的先验概率情况（此时，推导式 (7.8) 无法去除乘积中的诸先验概率  $P(x_i)$  项）。在异类分类器的各种组合模式的开发中，通常都在性能与精度之间进行了折中。经验表明，求和规则在实现上是最佳的<sup>[29]</sup>。

## 7.7 最优分布式贝叶斯目标分类方法

本节提出一个最优分布式贝叶斯目标分类方法，并与 naive 贝叶斯融合分类方法进行了比较<sup>[34]</sup>。贝叶斯目标分类采用 7.3 节中所讨论的通用方法，我们在这里仍采用贝叶斯网络形式表示目标类别与传感器测量的关系模型。贝叶斯网络<sup>[35, 36]</sup>是随机模型的一种（因果关系）图形表示，是一个有向图。图中的节点表示所关注的随机变量或随机向量，有向线表示变量之间的因果关系。一个动态贝叶斯网络中的某些节点附以时间标记。贝叶斯网络的一个关键特征使其能够显式表示最优分布式目标分类所需要的条件独立性。图 7.13 给出了采用两个传感器测量的目标分类动态贝叶斯网络模型。该网络中的识别变量是目标类别  $x_T$ 、目标的静态特征  $x_S$ （如目标尺寸）和随时间变化的目标动态特征  $x_D$ （如视角），它们所依赖的是每个传感器对该目标的测量  $y_i(t)$   $i=1, 2$ 。

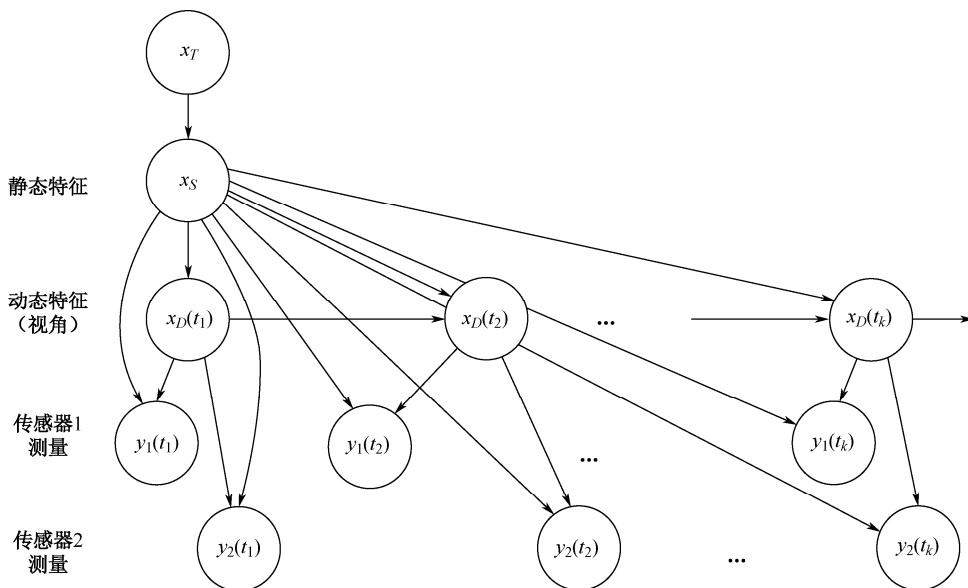


图 7.13 关于目标分类的动态贝叶斯网络模型

该贝叶斯网络结构展示了网络中各随机变量之间的相互依赖关系，各变量之间的定量关系通过前级节点状态（概率）向后级节点状态的条件转移概率来表示。图 7.13 中的这些概率定义如下：

- $P(x_T)$ ：目标类别  $x_T$  的先验概率。
- $P(x_S | x_T)$ ：给定类别的目标静态特征  $x_S$  的条件概率。
- $P[x_D(t_k) | x_D(t_{k-1}), x_S]$ ：给出时间  $t_{k-1}$  时刻动态特征  $x_D(t_{k-1})$  和静态特征  $x_S$  的情况下， $t_k$  时刻目标动态特性  $x_D(t_k)$  的预测概率。若动态变化不依赖于静态特征，则该条件概率变成  $P[x_D(t_k) | x_D(t_{k-1})]$ ，即动态特征转移概率。
- $P[y_i(t_k) | x_D(t_k), x_S]$ ：给出  $t_k$  时刻动态特征  $x_D(t_k)$  和静态特征  $x_S$  的情况下，传感器  $i$  在  $t_k$  时刻对该目标出现测量  $y_i(t_k)$  的概率，即条件似然函数。这个概率反映动态特征和静

态特征对测量的影响。

从图 7.4 中可以看出：

- 目标的静态特征既对动态特征有影响，又对两个传感器的测量有影响；
- 目标的动态特征影响两个传感器测量；
- 目标分类影响其静态特征并通过静态特征影响其动态特征和两传感器测量。

### 7.7.1 集中式目标分类算法

设  $Y(t_k) = [y(t_1), y(t_2), \dots, y(t_k)]$  是来自一个或多个传感器直到  $t_k$  时刻累积的对目标  $x_T$  的测量，集中式目标分类算法旨在计算给出累积测量  $Y(t_k)$  的情况下该目标分类的后验概率  $P[x_T | Y(t_k)]$ 。对于图 7.13 给出的目标分类贝叶斯网络模型，该后验概率的集中式递推计算步骤如下<sup>[34]</sup>：

- ① 估计  $t_k$  时刻的动态与静态联合特征。

预测

$$\begin{aligned} & P[x_S, x_D(t_k) | Y(t_{k-1})] \\ &= \int P[x_D(t_k) | x_D(t_{k-1}), x_S] P[x_S, x_D(t_{k-1}) | Y(t_{k-1})] dx_D(t_{k-1}) \end{aligned} \quad (7.9)$$

更新

$$P[x_S, x_D(t_k) | Y(t_k)] = C^{-1} P[y(t_k) | x_D(t_k), x_S] P[x_S, x_D(t_k) | Y(t_{k-1})] \quad (7.10)$$

- ② 估计  $t_k$  时刻的静态特征  $x_S$ ：

$$P[x_S | Y(t_k)] = \int P[x_S, x_D(t_k) | Y(t_k)] dx_D(t_k) \quad (7.11)$$

- ③ 估计  $t_k$  时刻的目标类别：

$$P[x_T | Y(t_k)] = \int P[x_S | Y(t_k)] P(x_T | x_S) dx_S \quad (7.12)$$

从图 7.13 给出的目标分类贝叶斯网络模型可以看出，两传感器测量直接依赖于该目标的两个特征，即静态特征  $x_S$  和动态特征  $x_D(t)$ ，因此按式 (7.9) 和式 (7.10) 计算  $x_S$  和  $x_D(t)$  的联合估计是获得目标分类后验概率的关键，每当接收到一个新的测量，都要对该联合估计进行更新。求取目标分类估计  $x_T$  即步骤②和③基本上是一个解耦问题，在应用中当测量比较充分，动态和静态特征估计比较精确时，才能够执行步骤②和③，实现目标分类的后验概率更新，使该目标分类后验概率估计满足应用的信度要求。

通过引入适宜的传感器测量模型，式 (7.9) ~ 式 (7.12) 可以应用于一个局部融合代理处理来自单一传感器的测量，也可用于一个集中融合代理处理多个传感器的测量。但需要指出的是，联合特征  $(x_S, x_D)$  的预测方程要求传感器测量是独立的，即要求不同的传感器独立获取目标的静态特征和动态特征。

### 7.7.2 分布式目标分类算法

分布式目标分类识别问题是通过组合局部分类代理的目标分类估计来获得该目标分类

的全局更新（改善）估计。该问题有两个紧密耦合的部分，第一个是确定各局部分类代理向全局分类节点发送什么信息，即各局部分类代理发送对该目标的分类识别的说明包含什么内容；第二个问题是全局分类节点如何组合接收的各局部代理分类说明。

我们知道，如果目标的各局部分类估计说明只是分类标记，如坦克、步兵战车或自主火炮，而不包含各分类标记的估计信度，全局分类节点只能采取表决方式得到次优全局更新估计。一个通用的、较好的方法是在每个局部分类代理向全局分类节点传输的分类估计说明中，既包含局部分类标记，又含有基于自身测量的该分类标记条件概率  $P(x_T | Y_i)$ ,  $i=1,2$ 。此时全局分类节点可采用“乘规则”组合这些概率：

$$P(x_T | Y_1, Y_2) = C^{-1} P(x_T | Y_1) P(x_T | Y_2) \quad (7.13)$$

然而，对于要识别的目标类别  $x_T$ ，测量集合  $Y_1$  和  $Y_2$  通常不是条件独立的，故式（7.13）给出的全局分类更新仍只是次优的。下面给出用于分布式目标分类的一个通用分布式估计方法<sup>[37]</sup>。

### 1. 贝叶斯分布融合分类算法

设  $x$  是关注目标的分类状态，可以是目标类别、静态特征或动态特征。设  $Y_1$  和  $Y_2$  分别是来自传感器 1 和传感器 2 的分类状态测量集合。若两局部状态测量集合基于分类状态是条件独立的，即  $P(Y_1, Y_2 | x) = P(Y_1 | x) P(Y_2 | x)$ ，则能够从两局部分类状态的后验概率获得全局分类状态的后验概率<sup>[38]</sup>：

$$P(x | Y_1, Y_2) = C_{12}^{-1} \frac{P(x | Y_1) P(x | Y_2)}{P(x)} \quad (7.14)$$

式中， $C_{12}^{-1} = \frac{P(Y_1) P(Y_2)}{P(Y_1, Y_2)}$  是归一化常数，当  $Y_1$  和  $Y_2$  相互独立时， $C_{12} = 1$ 。这里，分类状态的先验概率  $P(x)$  出现在分母中，这是因为该共用先验信息在计算每个局部分类状态后验概率时都被用到，即重复使用，因此要予以去除。注意测量  $Y_1$  和  $Y_2$  的条件独立性：

$$\begin{aligned} P(x | Y_1, Y_2) &= P(Y_1, Y_2 | x) P(x) / P(Y_1, Y_2) \\ &= P(Y_1 | x) P(Y_2 | x) P(x) / P(Y_1, Y_2) \\ &= P(Y_1 | x) P(x | Y_2) P(Y_2) / P(Y_1, Y_2) \end{aligned}$$

即

$$P(x | Y_1, Y_2) = C_1^{-1} P(Y_1 | x) P(x | Y_2), \quad C_1 = P(Y_1, Y_2) / P(Y_2) \quad (7.15)$$

同理

$$P(x | Y_1, Y_2) = C_2^{-1} P(Y_2 | x) P(x | Y_1), \quad C_2 = P(Y_1, Y_2) / P(Y_1) \quad (7.16)$$

其中  $C_1$ 、 $C_2$  为归一化参数。

对于两层分类融合识别结构，设  $Y_F$  是高层融合代理  $F$  的累积测量集合， $Y_i$  是低层代理  $i$  ( $i=1,2$ ) 用于估计其局部分类的新测量集合，并且这两个测量集合不相交，即  $Y_F \cap Y_i = \emptyset$ 。若选择的目标分类状态  $x$  使  $Y_F$  与  $Y_i$  条件独立，则式（7.14）和式（7.15）就变成如下融合分类估计方程：

$$P(x|Y_i, Y_F) = C_{iF}^{-1} \frac{P(x|Y_i)P(x|Y_F)}{P(x)} \quad (7.17)$$

或

$$P(x|Y_i, Y_F) = C_i^{-1} P(Y_i|x)P(x|Y_F) \quad (7.18)$$

式(7.17)和式(7.18)分别表示传输与融合相结合的两种不同方法,它们是等价的。式(7.17)表示低层识别代理 $i$ 向高层识别代理 $F$ 发送基于其新测量集合 $Y_i$ 产生的局部分类识别后验概率 $P(x|Y_i)$ ,然后高层代理 $F$ 利用式(7.17)将它与基于自身测量集合 $Y_F$ 产生的目标分类识别后验概率 $P(x|Y_F)$ 进行组合,产生目标的全局分类的更新估计。而式(7.18)则是低层代理 $i$ 向高层代理 $F$ 发送其局部似然函数 $P(Y_i|x)$ ,然后高层代理利用式(7.18)将它与自身的目标分类识别概率 $P(x|Y_F)$ 进行组合,生成目标全局分类的更新估计。

式(7.14)~式(7.18)成为最优全局分类识别的一个必要条件是两局部测量集合 $Y_1$ 与 $Y_2$ 的条件独立假设。从图7.13可以看出,选择目标分类 $x_T$ 作为识别状态不满足该条件独立假设,因为两传感器对目标类别 $x_T$ 的直接测量含有 $x_T$ 的同一过程噪声(即共用的类别模糊性),因此产生 $Y_1$ 与 $Y_2$ 之间的交叉协方差。这样一来,按上述诸式获得的目标类别概率估计是次优的。

## 2. 最优分布式目标分类识别算法

考虑图7.13给出的目标分类识别的贝叶斯网络模型,并考虑无反馈融合识别层次结构。每个低层局部分类识别代理基于自上次发送以来其自身传感器新测量集合生成的一个目标分类状态的局部后验概率,周期性地向高层代理发送。高层代理则将接收的低层代理局部分类状态后验概率与自身当前的目标分类后验概率进行组合,生成目标分类状态的全局后验概率的更新估计。

图7.14给出了基于图7.13描述的贝叶斯网络模型的目标动态特征 $x_D$ 的识别过程。图中,两传感器测量如该图上、下阴影部分各框所示,各传感器测量主要来源于该图中部各(椭圆)框中的目标动态特征 $x_D$ 。该图中没有包含高层节点目标类别 $x_T$ 与静态特征 $x_S$ 。

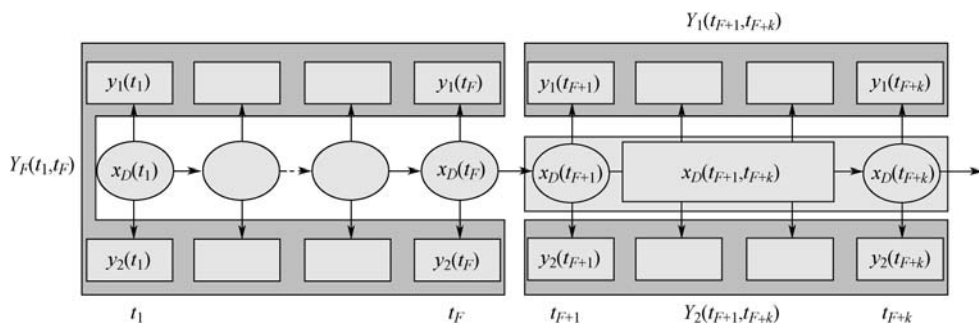


图 7.14 目标动态特征 $x_D$ 的识别过程

由图7.14的局部和全局融合结果,进行目标动态特征 $x_D$ 最优识别的过程描述如下:

该图在左半部分是一个时间周期 $[t_1, t_F]$ 内目标动态特征 $x_D$ 的局部测量 $\{y_i(t_k)\}_{k=1}^F$  ( $i=1,2$ )

和全局测量的累积集合  $Y_F(t_1, t_F)$ 。每个时刻的测量都来自该时刻的目标动态特征  $x_D$ 。该图右半部分是  $(t_{F+1}, t_{F+k})$  内每个传感器累积测量的集合  $Y_i(t_{F+1}, t_{F+k}) \triangleq [y_i(t_{F+1}), \dots, y_i(t_{F+k})]$ （自上一次全局融合识别时间  $t_F$  以后收集的测量）。由于  $Y_i(t_{F+1}, t_{F+k}) (i=1, 2)$  与  $Y_F(t_1, t_F)$  是不同的时间所获得的，故可假设它们是相互独立的。

局部测量集合  $Y_i (i=1, 2)$  与全局测量集合  $Y_F$  之间的条件独立假设能够使全局融合方程 (7.17) 和 (7.18) 保持最优。贝叶斯网络提供了确定这个条件独立性的一个易于理解的方法。从图 7.13 和图 7.14 可以看到，在给出静态特征  $x_S$  和动态特征  $x_D(t_{F+1}, t_{F+k}) \triangleq [x_D(t_{F+1}), \dots, x_D(t_{F+k})]$  的条件下，测量集合  $Y_i(t_{F+1}, t_{F+k}) (i=1, 2)$  与  $Y_F(t_1, t_F)$  是条件独立的，这里的全局代理的测量集合  $Y_F$  可以由自身传感器测量及各局部传感器测量组成。显然在给出  $x_S$  和同一时间动态特征  $x_D(t_k)$  的条件下， $Y_F(t_k)$  与  $Y_i(t_k)$  的条件独立性假设将遭到破坏。

在测量集合  $Y_i(t_{F+1}, t_{F+k})$  与  $Y_F(t_1, t_F)$  关于  $x_D(t_{F+1}, t_{F+k})$  条件独立的情况下，全局融合由以下步骤组成：

① 局部代理向全局代理传送的信息的计算。

局部代理向全面代理传送分类特征后验概率的情况。此时，局部代理计算基于本周期自身测量  $Y_i(t_{F+1}, t_{F+k})$  的目标分类特征的后验概率  $P[x_S, x_D(t_{F+1}, t_{F+k}) | Y_i(t_{F+1}, t_{F+k})]$ 。计算过程是：对  $n = F+1, \dots, F+k-1$ ，利用下述公式递推计算：

$$\begin{aligned} & P[x_S, x_D(t_{F+1}, t_{n+1}) | Y_i(t_{F+1}, t_{n+1})] \\ & = C^{-1} P[y_i(t_{n+1}) | x_S, x_D(t_{n+1})] P[x_D(t_{n+1}) | x_S, x_D(t_n)] P[x_S, x_D(t_{F+1}, t_n) | Y_i(t_{F+1}, t_n)] \end{aligned} \quad (7.19)$$

式中， $t_n$  时刻的初值  $x_D(t_{F+1}, t_{F+1}) = x_D(t_{F+1})$ ， $Y_i(t_{F+1}, t_{F+1}) = Y_i(t_{F+1})$ ，于是当  $n = F+k-1$  时，即获得  $P[x_S, x_D(t_{F+1}, t_{F+k})]$ 。注意式 (7.19) 右侧第一个因子是新测量  $y_i(t_{n+1})$  的条件似然函数，第二个因子是动态特征状态  $x_D(t_n)$  向  $x_D(t_{n+1})$  的转移概率，第三个因子是上一  $t_n$  时刻分类特征  $[x_S, x_D(t_{n+1}, t_n)]$  的后验估计概率，第二和第三个因子之积可以作为  $t_{n+1}$  时刻分类特征预测概率，即先验概率。

局部代理向全局代理仅传送条件似然函数情况。该似然函数  $P[Y_i(t_{F+1}, t_{F+k}) | x_S, x_D(t_{F+1}, t_{F+k})]$  可直接由式 (7.20) 计算：

$$P[Y_i(t_{F+1}, t_{F+k}) | x_S, x_D(t_{F+1}, t_{F+k})] = \prod_{m=F+1}^{F+k} P[Y_i(t_m) | x_S, x_D(t_m)] \quad (7.20)$$

该式是由本周期测量集合  $Y_i(t_{F+1}, t_{F+k})$  中各单一测量之间的条件独立性获得的。此时，为了获得向全局代理发送的分类特征后验概率，各局部代理还需要计算其在  $(t_{F+1}, t_{F+k})$  时间周期的目标特征的先验概率。该先验概率  $P[x_S, x_D(t_{F+1}, t_{F+k})]$  可通过下式递推得到：

$$\begin{aligned} P[x_S, x_D(t_{F+1}, t_{n+1})] &= P[x_S, x_D(t_{F+1}, t_n), x_D(t_{n+1})] \\ &= P[x_D(t_{n+1}) | x_S, x_D(t_n)] P[x_S, x_D(t_{F+1}, t_n)] \end{aligned} \quad (7.21)$$

该递推过程对  $t_n = t_{F+1}, t_{F+2}, \dots$  时刻逐一进行，当  $t = F+k-1$  时，即得所需要的先验概率。

式 (7.21) 右端第一个因子表示动态特征  $x_D$ （从  $t_n$  到  $t_{n+1}$ ）的一步状态转移概率，第二个因子是转移开始时间  $(t_{F+1}, t_n)$  的特征状态概率，实际上就是代理  $i$  在  $t_n$  时刻的特征状态的后验概率

$P[x_S, x_D(t_{F+1}, t_n) | Y_i(t_{F+1}, t_n)]$ ，其初值为  $t_n = t_{F+1}$  时刻的  $P[x_S, x_D(t_{F+1}) | Y_i(t_{F+1})]$ ，可从  $P[x_S, x_D(t_F) | Y_i(t_1, t_F)]$  向  $t_{F+1}$  时刻外推获得。

### ② 全局代理预测计算。

全局代理预测  $(t_{F+1}, t_{F+k})$  各时刻的分类特征概率  $P[x_S, x_D(t_{F+1}, t_{F+k}) | Y_F(t_1, t_F)]$  自然要通过  $P[x_S, x_D(t_F) | Y_F(t_1, t_F)]$  外推获得，首先进行一步外推：

$$\begin{aligned} & P[x_S, x_D(t_{F+1}) | Y_F(t_1, t_F)] \\ &= \int P[x_S, x_D(t_{F+1}), x_D(t_F) | Y_F(t_1, t_F)] dx_D(t_F) \\ &= \int P[x_D(t_{F+1}) | x_D(t_F), x_S] P[x_S, x_D(t_F) | Y_F(t_1, t_F)] dx_D(t_F) \end{aligned} \quad (7.22)$$

式 (7.22) 右端积分式中第一个因子是动态特征  $x_D$  由  $t_F$  时刻向  $t_{F+1}$  时刻的转移概率，第二个因子是  $x_D$  在  $t_F$  时刻的后验概率。然后，再进行逐步外推：

$$\begin{aligned} & P[x_S, x_D(t_{F+1}, t_{F+i+1}) | Y_F(t_1, t_F)] \\ &= P[x_S, x_D(t_{F+1}, t_{F+i}), x_D(t_{F+i+1}) | Y_F(t_1, t_F)] \\ &= P[x_D(t_{F+i+1}) | x_S, x_D(t_{F+i})] P[x_S, x_D(t_{F+1}, t_{F+i}) | Y_F(t_1, t_F)] \end{aligned} \quad (7.23)$$

式 (7.23) 右端第一个因子是动态特征  $x_D$  由时刻  $t_{F+i}$  向时刻  $t_{F+i+1}$  的转移概率，第二个因子是  $x_D$  在  $(t_{F+1}, t_{F+i})$  时间基于测量  $Y_F(t_1, t_F)$  的条件预测概率。式 (7.23) 对  $i = 1, 2, \dots, k-1$  逐步进行即可得到  $P[x_S, x_D(t_{F+1}, t_{F+k}) | Y_F(t_1, t_F)]$ 。

### ③ 全局代理融合分类识别计算。

在获得全局代理预测概率  $P[x_S, x_D(t_{F+1}, t_{F+k}) | Y_F(t_1, t_F)]$  和局部代理  $i$  发送的分类特征当前局部后验概率之后，鉴于以图 7.14 的局部代理  $i$  的当前测量集合  $Y_i(t_{F+1}, t_{F+k})$  与全局代理之前测量集合  $Y_F(t_1, t_F)$  基于分类特征状态的条件独立性，利用式 (7.17) 即可得到高层代理  $(t_{F+1}, t_{F+k})$  时刻分类特征状态的后验概率：

$$\begin{aligned} & P[x_S, x_D(t_{F+1}, t_{F+k}) | Y_F(t_1, t_F), Y_i(t_{F+1}, t_{F+k})] \\ &= C^{-1} \frac{P[x_S, x_D(t_{F+1}, t_{F+k}) | Y_F(t_1, t_F)] P[x_S, x_D(t_{F+1}, t_{F+k}) | Y_i(t_{F+1}, t_{F+k})]}{P[x_S, x_D(t_{F+1}, t_{F+k})]} \end{aligned} \quad (7.24)$$

式中分母表示被去除的先验概率  $P[x_S, x_D(t_{F+1}, t_{F+k})]$ ，按式 (7.21) 计算。

当局部代理向全局代理传送条件似然函数时，全局代理也可采用式 (7.18) 计算融合的分类特征的当前后验概率：

$$\begin{aligned} & P[x_S, x_D(t_{F+1}, t_{F+k}) | Y_F(t_1, t_F), Y_i(t_{F+1}, t_{F+k})] \\ &= C_i^{-1} P[Y_i(t_{F+1}, t_{F+k}) | x_S, x_D(t_{F+1}, t_{F+k})] P[x_S, x_D(t_{F+1}, t_{F+k}) | Y_F(t_1, t_F)] \end{aligned} \quad (7.25)$$

值得指出的是，如果全局代理在融合了某局部代理在  $(t_{F+1}, t_{F+k})$  周期中的分类状态后验概率  $P[x_S, x_D(t_{F+1}, t_{F+k}) | Y_i(t_{F+1}, t_{F+k})]$  之后，其获得的当前后验概率  $P[x_S, x_D(t_{F+1}, t_{F+k}) | Y_F(t_{F+1}, t_{F+k})]$  就包含有对  $(t_{F+1}, t_{F+k})$  周期的预测。此时若再对  $(t_{F+1}, t_{F+k})$  周期中其他局部代理的分类状态后验概率进行融合，就不需要步骤②的预测计算了。

基于图 7.14 和以上分析描述的各计算步骤， $(t_{F+1}, t_{F+k})$  周期目标分类特征最优分布式后验估计算法流程如图 7.15 所示，其中  $n$  为局部代理（传感器）数量。



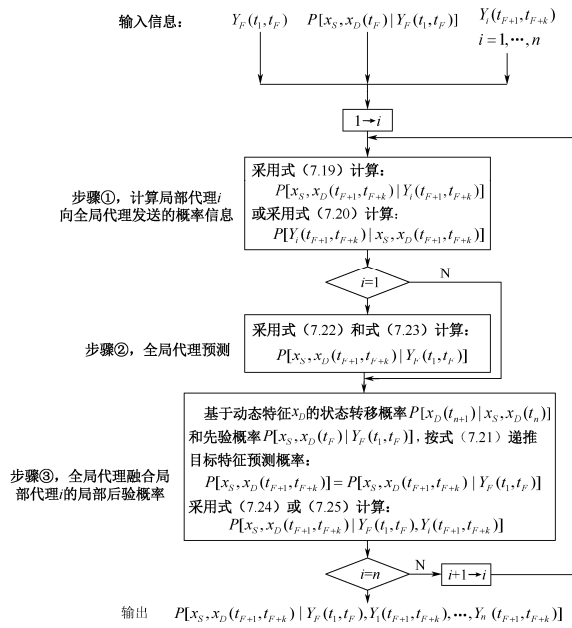


图 7.15 目标分类特征最优分布式后验估计算法流程

在获得目标分类特征的周期最优后验概率  $P[x_S, x_D(t_{F+1}, t_{F+k}) | Y_F(t_f, t_F), Y_i(t_{F+1}, t_{F+k})]$  ( $i=1, \dots, n$ ) 后, 即可按式 (7.11) 和式 (7.12) 分别解耦估计获取静态特征  $x_S$  和目标类别  $x_T$  的周期分布式最优分类识别后验概率。注意式 (7.11) 和式 (7.12) 中的时间  $t_k$ , 此时应代以  $t_{F+1}, \dots, t_{F+k}$ , 即该估计周期的  $k$  个测量时间。

### 7.7.3 分布式目标分类识别系统的通信策略

在分布式目标分类识别系统中, 由于各局部代理不需要将其测量向融合中心发送, 故能减少通信带宽需求, 这是相比集中式分类识别系统的优势之一。如果每个局部代理必须在其传感器观测时间传输它们的充分统计量, 这个优势也不明显, 因为充分统计量是关于测量的一些概率分布, 信息量只有有限减少; 另一方面, 由于一个新的测量可能并不含有充分的新信息, 因此一个局部代理并不需要在接收到每个新测量后都频繁地发送其融合结果。这样看来, 一个局部代理的通信传输只应出现在需要时, 即一个局部代理的信息发送不是仅仅依赖于其获取信息量的增加。

由上述分析所引出的一个基于信息推动的通信策略是: 一个代理基于对其局部融合结果的监视分析, 判断自上次通信以来是否获得了比较充分的新信息, 以决定其局部融合结果是否发送。

设  $t_F$  是局部代理  $i$  对融合中心的上一次发送时间,  $t_k$  (大于  $t_F$ ) 是当前时间。再设  $Y_i(t_k)$  是自  $t_F$  以来代理  $i$  的传感器累积的新测量集合,  $P[x | Y_i(t_k)]$  是分类状态  $x$  基于新测量集合  $Y_i(t_k)$  的当前后验分布,  $P[x | Y_i(t_F)]$  是分类状态  $x$  上一次发送时间  $t_F$  的后验分布。于是这里我们给出基于信息驱动的通信策略是: 局部代理  $i$  要确定分类状态  $x$  的这两个时间的后验分布是否存在充分差异, 通过其间的某个距离函数  $D\{P[x | Y_i(t_F)], P[x | Y_i(t_k)]\}$  是否大于一个预设的距离门限  $d$  进行判断:

$$D\{P[x|Y_i(t_F)], P[x|Y_i(t_k)]\} > d \quad (7.26)$$

使该式成立的最近时间  $t_k$  就是产生充分的新信息的时间, 此时, 局部代理  $i$  将该时间的融合结果向融合中心发送。注意: 式(7.26)中的  $P[x|Y_i(t_F)]$  是外推到  $t_k$  时刻的分类状态  $x(t_k)$  的预测概率。

两概率分布  $P_1$  和  $P_2$  的距离有多种度量方法。一个常用的Kullback—Leibler (KL) 散度<sup>[39]</sup>是:

$$D(P_2, P_1) = \int_x P_2(x) \ln[P_2(x) | P_1(x)] dx \quad (7.27)$$

或

$$D(P_2, P_1) = \sum_{x_i \in X} P_2(x_i) \ln[P_2(x_i) | P_1(x_i)] \quad (7.28)$$

其中式(7.27)是连续分布  $P_2(x)$  与  $P_1(x)$  之间的距离, 式(7.28)是离散分布  $[P_2(x_1), \dots, P_2(x_i)]$  与  $[P_1(x_1), \dots, P_1(x_i)]$  之间的距离 ( $x_1, x_2, \dots, x_i \in X$ )。

## 7.8 分布式目标分类识别算法比较

### 7.8.1 目标分类识别算法性能仿真与评估方法

#### 1. 仿真剧本和数据生成

目标分类识别算法采用的仿真剧本如下:

- 假设两个传感器采用如图 7.13 给出的目标分类贝叶斯网络模型;
- 目标类别有 3 个:  $T_1, T_2, T_3$ , 先验概率均为 1/3;
- 单一静态特征  $x_s$  (目标尺寸) 均被两传感器观测到, 三个目标类别的静态特征  $x_s$  均为高斯随机变量, 均值分别为  $m_j = 3, 0, 3$ , 方差均为  $\sigma_j^2 = 1 (j = 1, 2, 3)$ ;
- 不同静态特征概率分布之间的距离用  $D_{ij} = (m_j - m_i)^2 / \sigma_i^2$  表示;
- 目标类别的动态特征  $x_D(t_k)$  表示在  $[0, \pi]$  之间变化的视角 (目标观测方位), 按照马尔可夫状态转移概率  $P[x_D(t_{k+1}) | x_D(t_k)] = 0.2$  从一个单元向另一个邻接的单元转移;
- 静态特征  $x_s$  与动态特征  $x_D$  按如下几何互补条件生成两传感器的观测信号:

$$y_1(t_k) = x_s \sin x_D(t_k) + V_1(t_k) \quad (7.29)$$

$$y_2(t_k) = x_s \cos x_D(t_k) + V_2(t_k) \quad (7.30)$$

这里的观测信号是带有观测噪声的目标观测尺寸, 其中测量噪声方差  $V_i(t_k)$  为  $\sigma_{v_i}^2 = 0.04$  ( $i = 1, 2$ )。

#### 2. 性能评估方法

我们采用 7.7 节描述的目标分类算法。由于其中的公式无法以解析方式评估, 我们将静态特征  $x_s$  和动态特征  $x_D$  离散化, 并将式(7.9)从积分变为求和, 保留更新方程(7.10)中

的连续测量值。

在该仿真剧本中，考虑两个通信策略：固定策略和自适应策略。固定设置的通信策略是每个代理（传感器）与融合中心的通信出现在观测间隔固定倍数的区间上，而自适应通信策略则使用 7.7.3 节讨论的基于信息驱动的策略所给出的算法。局部代理  $i$  在通信时间  $t_{F+k}$  向融合中心发送自上次融合（发送）时间  $t_{F_i}$  之后所接收的累积观测信息  $Y_i(t_{F_i+1}, t_{F_i+k})$  基于特征  $x_S$  和  $x_D(t_k)$  的条件似然函数  $P[Y_i(t_{F_i+1}, t_k) | x_S, x_D(t_k)]$ ，其中  $x_D(t_k)$  为取一个单一时间  $t_k$  的动态特征作为  $x_D[t_{F_i+1}, t_{F_i+k}]$  的近似， $t_k \in (t_{F_i+1}, t_{F_i+k})$  可以取其中某一固定时刻，也可按 7.7.3 节描述的基于信息驱动的自适应通信策略，在给出概率距离门限  $d$  之后，按式 (7.27) 或式 (7.28) 计算出大于门限  $d$  的 KL 散度  $D\{P[x_S, x_D(t_{F_i})], P[x_S, x_D(t_k)]\}$  所确定的发送时间  $t_k$ 。因为传输一个多维动态特征向量是不现实的，否则就只能在获得每个新测量之后都进行融合发送，这更是不现实（也不需要）的。

在局部代理向全局代理发送时间  $t_k$  确定后，即可按 7.7.2 节描述的目标分类特征识别算法步骤（或按图 7.15 给出的算法流程），基于测量  $Y_i(t_{F_i+1}, t_k)$  求取目标联合分类特征  $[x_S, x_D(t_k)]$  的后验估计  $P[x_S, x_D(t_k) | Y_i(t_{F_i+1}, t_k)]$ ，或条件似然函数  $p[Y_i(t_{F_i+1}, t_k) | x_S, x_D(t_{F_i+1}, t_k)]$ ，然后发送给全局代理，全局代理计算目标动态特征  $x_D$  对  $t_k$  时刻预测概率，并最终得到  $t_k$  时刻的目标动态特征  $x_D$  的全局后验概率。然后采用离散化的式 (7.11) 和式 (7.12) 分别解耦求取目标静态特征  $x_S$  和类别  $x_T$  的后验估计。如果每个代理（传感器）直接采用产生式模式计算生成目标类别的局部后验估计，然后再融合获得目标类别的全局后验概率，那么由于两传感器测量对目标类别条件独立的假设不一定成立，获得的目标类别全局后验估计只能是次优的，但其可以作为与其他算法比较的参考。

目标分类方法性能评估采用两个度量指标。第一个是目标分类期望后验概率（Expected Posterior Probability, EPP），定义为

$$\text{EPP}(T_j | T_j) = E[P(x_T = T_j | Y) / x_T = T_j] \quad (7.31)$$

式中， $T_j$  是目标真实类别， $Y$  是该后验概率估计所使用的测量数据。目标分类方法的第二个性能评估度量指标是目标分类估计的均方根（Root Mean Square, RMS）误差，定义为

$$\text{RMS}(T_j) = \sqrt{\sum_{x_T} [P(x_T / Y) - \delta(x_T; T_j)]^2} \quad (7.32)$$

式中， $\delta(x_T; T_j)$  是狄拉克函数，当  $x_T = T_j$  时为 1，否则为 0。

## 7.8.2 目标分类融合识别算法仿真比较

使用蒙特卡洛仿真比较 5 种目标分类识别算法的性能：仅使用传感器 1、仅使用传感器 2、集中式融合分类、产生式规则融合分类及利用分类特征（有一定近似）的分布式目标分类。每种分类识别结果都假设真实的目标类别是  $T_2$ ，因为采用  $T_1$  或  $T_3$  会出现难以区分的混乱情况。

对 5 种目标分类算法的识别结果采用基于真实目标类别  $T_2$  的 EPP 度量和 RMS 误差度量指标进行比较，如图 7.16 和图 7.17 所示。




图 7.16 目标正确分类 EPP—时间




图 7.17 目标分类概率误差 RMS—时间

从图 7.16 和图 7.17 可以看出，集中式目标分类识别性能最好，随后是分布式目标分类，分布式目标分类性能随着测量数量的增加逐渐接近集中式分类识别性能。若仅考虑 EPP 度量指标，从图 7.16 看到产生式规则融合识别概率似乎在实际上比分布式目标分类性能更好；但从图 7.17 中的误差 RMS 看到，其分类识别性能不如分布式目标分类方法。最后，从这两图中皆可看出，使用单一传感器的目标分类性能总是最差的。

图 7.18 和图 7.19 给出了目标分类特征概率分布之间的间隔对各种目标分类识别算法性能的影响。从图中可以看出，各种算法的分类性能指标 EPP (RMS) 之间的“距离”随特征分布间隔的增大而增加。该仿真中使用的静态特征分布基线间隔是  $D_{ij} = (m_j - m_i)^2 / \sigma_i^2$  ( $i, j = 1, 2, 3; i \neq j$ )。




图 7.18 正确分类 EPP—目标类别特征分布间隔




图 7.19 目标分类概率误差 RMS—目标类别特征分布间隔

图 7.20 和图 7.21 给出了目标动态特征转移概率  $P[D(t_{k+1})/D(t_k)]$  对各分类算法性能的影响。




图 7.20 正确分类 EPP—特征转移概率




图 7.21 目标分类概率误差 RMS—特征转移概率

从图 7.20 和图 7.21 可以看出,单一传感器分类性能随转移概率的增加所获得的裨益(即其增加或减少的梯度)多于两传感器融合分类性能,这是由于随着目标类别的动态特征转移概率的增加,目标静态特征的可观测性得到改善,因为较大的动态特征转移概率意味着观测视角的更多移动变化,从而能够产生更好的平均可观测性。

图 7.22 和图 7.23 还比较了使用自适应通信策略和固定设置通信策略的情况下分布式分类的性能,其中其他分类算法性能(集中式、单一传感器分类及产生式规则融合分类)仅作为参考画出。

从图 7.22 和图 7.23 可以看出,自适应通信策略的分布式分类性能比固定设置通信策略下的分布式分类性能好,当平均通信次数大于 5 次时,基于自适应通信策略的分布式分类能达到集中式融合分类的性能,而固定设置的通信策略在 2 倍于这个数字(10)时,也达不到这一性能水平。




图 7.22 正确分类的 EPP—平均通信次数




图 7.23 目标分类概率误差 RMS—平均通信次数

## 7.9 本章小结

目标分类面对的是基于不同的目标特征分类等级和类别的目标属性识别问题,因此分类与识别二词经常混用,或统称为目标分类识别。分布式目标分类系统是指该功能分布在网络的不同节点上,并且包含多个层次。分布式目标分类最终要实现所需要的多层次多节点分类识别的综合优化,以满足与各识别节点耦合的作战应用需求。因此,分布式目标分类是分布式数据融合的一个重要领域,在实现方法上比集中式分类识别具有更大的难度,面临许多具有挑战性的新问题。

本章首先概述了目标分类识别的方法及其特点,目标类别与识别特征的关系以及目标分类方法的基本类型——“产生”型、“差异”型和混合型。然后描述了目标分类识别 4 级结构和混合结构,说明了分布式分类识别中的挑战性问题:显式重复计算、隐式重复计算,以及面临的对传统硬分类说明和混合不确定分类说明的融合分类问题。本章最大的贡献在于给出了最优分布式目标分类识别算法,从传统集中式分类的单一层次的不确定性优化,迈向两(多)层次不确定性优化,即从传统基于后验概率的贝叶斯集中式和分布式目标分类算法迈向多分类器的优化组合算法和最优分布式目标分类识别算法。特别是在最优分布式分类识别算法中,采用周期时差方法,基于目标分类特征状态的条件独立性建立了局部代理测量与全局代理测量,从而实现局部代理目标分类后验概率与全局代理目标分类后验概率的最优融合。本章最后描述了局部代理向全局代理传送目标分类局部后验概率的两种通信策略,并通过仿真实验验证了本章所建立的最优分布式目标分类算法和自适应通信策略的优势。

本章没有考虑含有成像技术的观测的分布式目标分类识别问题,但本章所讨论的一系列基础性、结构性问题和关于目标分类识别的分布式贝叶斯算法及最优分布式贝叶斯算法也可以应用于带有成像传感器的情况,但对于显式构造一个产生特定目标分类的传感器数据融合方法来说,仍存在困难。

## 参考文献

- [1] Martin E Liggins, David L Hall, James Llinas. Handbook of Multisensor Data Fusion Theory and Practice Second Edition. CRC Press Taylor & Francis Group Boca Raton, NewYork, 2008.
- [2] Zalta E N. Stanford Encyclopedia of Philosophy. <http://plato.stanford.edu/>.
- [3] Hartshorne C, P Weiss, A Burks, et al. The Collected Papers of Charles Sanders Peirce. Cambridge, MA: Harvard University Press.
- [4] 赵宗贵, 刁联旺. 信息融合工程实践——技术与方法. 北京: 国防工业出版社, 2015.
- [5] 刘海燕. 信息融合的几个关键技术研究. 解放军理工大学, 博士论文, 2007.
- [6] 王壮, 胡卫东, 郁文贤, 等. 基于均衡信度分配准则的冲突证据组合方法. 电子学报, 2001, 29(12): 1852-1855.
- [7] 赵宗贵, 刘海燕. 基于局部信度分配的证据合成方法. 现代电子工程, 2008, (2): 42-47.
- [8] Jousselme A L, Dominic G, Bosse E. A new distance between two bodies of evidence. Information fusion. 2001, 91-101.
- [9] Jean Derzent. Quantitative and Qualitative Information Fusion. International conference of Information Fusion, 杭州电子科技大学, 2009.
- [10] Bhanu B. Automatic target recognition: State of the art survey. IEEE Transactions on Aerospace and Electronic Systems, 1986, 22:364-379.
- [11] Roth M W. Survey of neural network technology for automatic target recognition. IEEE Transactions on Neural Networks, 1990, 1:28-43.
- [12] Cohen M N. An overview of radar-based, automatic, noncooperative target recognition techniques. Proceedings of IEEE International Conference on Systems Engineering, Dayton, OH, 1991, 29-34.
- [13] Novak L M. State of the art of SAR automatic target recognition. Proceedings of the IEEE 2000 International Radar Conference, Alexandria, VA, 2000, 836-843.
- [14] Murphy R, B Taylor. A survey of machine learning techniques for automatic target recognition. submitted to IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002.
- [15] Sudano J, The system probability information content (PIC) relationship to contributing components, combining independent multi-source beliefs, hybrid and pedigree pignistic probabilities. Proceedings of the 5th International Conference on Information Fusion, 2002.
- [16] 车德朝, 陈杰. 基于改进证据合成的地面目标身份识别方法. 指挥信息系统与技术, 2014, 5(1): 43-47.
- [17] R R Yager. On the Dempster-Shafer framework and new combination rules. Information Sciences, 1987, 41:93-138.
- [18] Chong C Y, S Mori. Graphical models for nonlinear distributed estimation. In Proceedings of the 7th International Conference on Information Fusion, Stockholm, Sweden, 2004.
- [19] Ng A Y, M I Jordan. On discriminative vs generative classifiers: A comparison of logistic regression and



- naive Bayes. *Advances in Neural Information Processing Systems*, 2002, 2:841–848.
- [20] Montillo, A. Generative versus discriminative modeling frameworks. Lecture at Temple University, 2010.
- [21] 刘海燕. 信息融合中几个关键技术研究. 解放军理工大学通信工程学院, 2007.
- [22] Tait P. *Introduction to Radar Target Recognition (Radar, Sonar & Navigation)*. London: The Institution of Engineering and Technology, 2005.
- [23] Sadjadi F A, B Javidi. *Physics of Automatic Target Recognition*. New York: Springer, 2007.
- [24] Nebabin V G. *Methods and Techniques of Radar Recognition*. Norwood, MA: Artech House, 1994.
- [25] Brooks R R, P Ramanathan, A M Sayed. Distributed target classification and tracking in sensor networks. *Proceedings of IEEE*, 2003, 91:1163–1171.
- [26] Kotecha J H, V Ramachandran, A M Sayeed. Distributed multitarget classification in wireless sensor networks. *IEEE Journal in Selected Areas in Communications*, 2005, 23:703–713.
- [27] Liggins II M, C Y Chong, I Kadar, et al. Distributed fusion architectures and algorithms for target tracking. *Proceedings IEEE*, 1997, 85:95–107.
- [28] Ho T K, J H Hull, S N Srihari. Decision combination in multiple classifier systems. *IEEE Transactions on Pattern Recognition and Machine Intelligence*, 1994, 16:66–75.
- [29] Kittler J, M Hatef, R P W Duin, et al. On combining classifiers. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1998, 20:226–239.
- [30] Kuncheva L I. A theoretical study on six classifier fusion strategies. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2002, 24:281–286.
- [31] Ruta D, B Gabrys. An overview of classifier fusion methods. *Computing and Information Systems*, 2000, 7:1–10.
- [32] Llinas J, R Acharya, C Ke. Fusion-based methods in the absence of quantitative classifier confidence. Report CMIF 6–98, Center for Multisource Information Fusion, New York, 1998.
- [33] Duda R O, P E Hart, D G Stork. *Pattern Classification*. New York: Wiley Interscience, 2001.
- [34] Chong C Y, S Mori. Distributed fusion and communication management for target identification. *Proceedings of the 8th International Conference on Information Fusion*, Philadelphia, PA, 2005.
- [35] Jensen F Y. *Bayesian Networks and Decision Graphs*. New York: Springer-Verlag, 2001.
- [36] Pearl, J. *Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference*. San Francisco, CA: Morgan Kaufman, 1988.
- [37] Chong, C Y, K C Chang, S Mori. Fundamentals of distributed estimation. In *Distributed Fusion for Net-Centric Operations*, Boca Raton, FL: CRC Press, 2012.
- [38] Chong C Y, S Mori, K C Chang. Distributed multitarget multisensor tracking. In *Multitarget-Multisensor Tracking: Advanced Applications*. Norwood, MA: Artech House. 1990, chapter 8, 247–295.
- [39] Kullback S, R A Leibler. On information and sufficiency. *Annals of Mathematical Statistics*, 1951, 22:79–86.

# 第 8 章 多传感器一致性数据融合

## 8.1 引言

在分布式感知系统中,每个传感器基于自身的局域探测独立遂行目标监视和识别判定任务,这些局部定位和识别信息再被传送到融合中心进行全局融合定位与识别。全局融合信息可以根据需要反馈给各传感器,以提升其目标监视与跟踪能力。由于传感器不精确以及环境噪声和人为干扰等因素,测量数据存在误差,进而导致融合信息具有不确定性。因此,必须寻找传感器测量数据与探测目标之间的某种关系,以评估和选择参与融合的测量数据。若某些测量被怀疑为有错,就不能参与融合;若某些传感器的测量数据与探测目标比较接近,才可以把它们融合在一起,以生成目标的高精度全局估计。为了滤除多传感器对某目标的大误差测量,文献[1]描述了基于充分冗余测量集合的粗点滤除方法,该方法在粗点滤除传统算法的基础上,提出了能避免大运算量的测量粗点统计递推滤除算法,并给出了立即滤除法和成批滤除法的求解步骤。为了提高融合精度,文献[2]描述了基于传感器测量信息按精度分组的融合方法,其理论基础是“大误差信息融合效果显著,并且精度相近信息的融合能更靠近真值”,因此,分组的合理性直接影响融合精度。文献[3]介绍了一种贴近度因子法实现传感器测量的合理分组。

若采用多传感器观测同一目标,为了检验传感器测量对该目标状态的贴近程度,Luo 提出采用置信距离测度来比较各传感器的测量数据<sup>[4]</sup>。对于一维多传感器测量数据,设第  $i$  个传感器和第  $j$  个传感器测得的目标数据(随机变量)分别为  $X_i$ ,  $X_j$ , 且均都服从正态分布,以它们的概率密度作为传感器的测量特征函数,记为  $p_i(x)$  和  $p_j(x)$ 。按照惯例,记  $x_i$ ,  $x_j$  分别为  $X_i$  和  $X_j$  的一次观测值。

为了反映观测数据  $x_i$  与  $x_j$  之间的偏差的大小,引进置信距离测度  $d_{ij}$  ( $d_{ji}$ ) 的概念,设

$$d_{ij} = 2 \left| \int_{x_j}^{x_i} p_i(x | x_i) dx \right| = 2A \quad (8.1)$$

$$d_{ji} = 2 \left| \int_{x_i}^{x_j} p_j(x | x_j) dx \right| = 2B \quad (8.2)$$

式中

$$p_i(x | x_i) = \frac{1}{\sqrt{2\pi}\sigma_i} \exp \left\{ -\frac{1}{2} \frac{(x - x_i)^2}{\sigma_i^2} \right\} \quad (8.3)$$

$$p_j(x|x_j) = \frac{1}{\sqrt{2\pi}\sigma_j} \exp\left\{-\frac{1}{2} \frac{(x-x_j)^2}{\sigma_j^2}\right\} \quad (8.4)$$

用  $A$ ,  $B$  分别表示概率密度曲线  $p_i(x|x_i)$ 、 $p_j(x|x_j)$  之下与区间  $(x_i, x_j)$  或  $(x_j, x_i)$  之上的面积, 如图 8.1 所示。

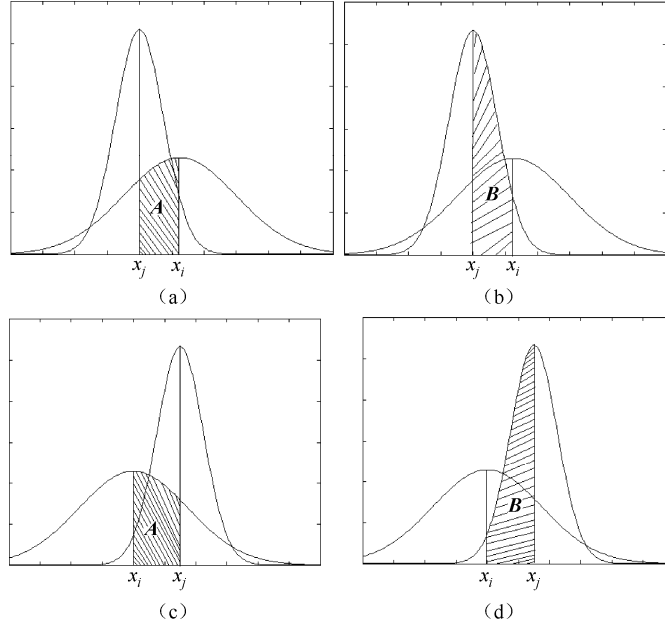


图 8.1 概率密度  $p_j(x|x_j)$  与  $p_i(x|x_i)$  的置信距离测度概念图

图 8.1 (a)、(b) 中阴影面积  $A$  和  $B$  分别表示  $x_i > x_j$  时的  $d_{ij}$  和  $d_{ji}$  的一半; 而图 8.1 (c)、(d) 中阴影面积  $A$  和  $B$  分别表示  $x_i < x_j$  时的  $d_{ij}$  和  $d_{ji}$  的一半。

$d_{ij}$  的值称为第  $i$  个传感器与第  $j$  个传感器测量数据的置信距离测度。

当  $x_i = x_j$  时,  $d_{ij} = d_{ji} = 0$ , 如图 8.2 (a) 所示; 当  $x_i \ll x_j$  或  $x_i \gg x_j$  时,  $d_{ij} = d_{ji} \approx 1$ 。如图 8.2 (b) 所示。一般地, 有:  $0 \leq d_{ij} \leq 1$ 。

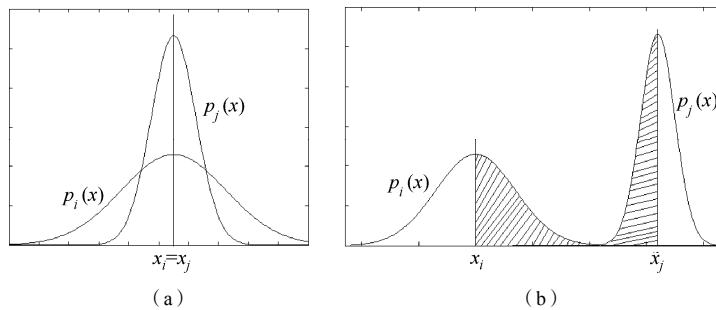


图 8.2 测量值相等和测量值相差甚远的情形

显然,  $d_{ij}$  的值越小,  $i$ ,  $j$  两个传感器对同一目标的观测值越靠近, 否则两观测相对偏差越大, 因此也称  $d_{ij}$  为第  $i$  个与第  $j$  个传感器测量的一致程度或贴近度。

由式(8.1)和式(8.2)不难得到:

$$d_{ij} = 2 \left| \int_{x_i}^{x_j} p_i(x | x_i) dx \right| = P_r \left( |Z| \leq \frac{|x_i - x_j|}{\sigma_i} \right) \quad (8.5)$$

$$d_{ji} = 2 \left| \int_{x_j}^{x_i} p_j(x | x_j) dx \right| = P_r \left( |Z| \leq \frac{|x_i - x_j|}{\sigma_j} \right) \quad (8.6)$$

式中,  $Z$  表示服从标准正态分布的随机变量。

如果有  $m$  个传感器观测同一个目标, 则相应地两两传感器测量之间的置信距离测度  $d_{ij}$  ( $i, j = 1, 2, \dots, m$ ) 构成一个矩阵  $D_{mm}$ 。

$$D_{mm} = \begin{bmatrix} d_{11} & d_{12} & \dots & d_{1m} \\ d_{21} & d_{22} & \dots & d_{2m} \\ \vdots & \vdots & \dots & \vdots \\ d_{m1} & d_{m2} & \dots & d_{mm} \end{bmatrix} \quad (8.7)$$

$D_{mm}$  被称为来源于同一探测目标的多传感器测量数据的置信距离矩阵。

当采用多传感器从不同的方向测量同一目标时, 根据经验或多次观测试验结果, 可以确定任一传感器  $i$  和  $j$  的一次测量  $x_i$  和  $x_j$  之间的置信距离测度  $d_{ij}$  的界限值 (关联门限值或阈值)  $\beta_{ij}$  ( $i, j = 1, 2, \dots, m$ )。设

$$r_{ij} = \begin{cases} 1 & d_{ij} \leq \beta_{ij} \\ 0 & d_{ij} > \beta_{ij} \end{cases}$$

$$R_{mm} = \begin{bmatrix} r_{11} & r_{12} & \dots & r_{1m} \\ r_{21} & r_{22} & \dots & r_{2m} \\ \vdots & \vdots & \dots & \vdots \\ r_{m1} & r_{m2} & \dots & r_{mm} \end{bmatrix} \quad (8.8)$$

式中,  $R_{mm}$  为  $m$  个传感器的一致性关系矩阵。由于一致性或相容性较好的测量数据才能融合产生更好性能 (精度) 的目标状态估计, 故这里的一致性也称为可融合性或相融性。

若  $r_{ij} = 0$ , 则认为第  $i$  个传感器与第  $j$  个传感器测量结果相融性 (一致性) 差, 或称它们之间相互不支持; 若  $r_{ij} = 1$ , 则认为第  $i$  个传感器与第  $j$  个传感器测量结果相融性 (一致性) 好, 称第  $i$  个传感器测量支持与第  $j$  个传感器测量的融合; 若  $r_{ij} = r_{ji} = 1$ , 称第  $i$  个传感器与第  $j$  个传感器相互支持, 如图 8.3 (b) 所示。



图 8.3 两传感器测量的支持关系

如果一个传感器被一组传感器所支持, 则称这个传感器的观测数据是有效的。若一个传感器不被其他传感器所支持, 或只被少数传感器所支持, 则称这个传感器的观测数据是无效或有效性较低的。多传感器测量同一目标时, 在剔除无效或有效性较低的数据之后所产生的

有效数据的集合称为融合集，融合集中数据的个数称为最佳融合数。

在上述关系矩阵  $R_{nm}$  的定义中，阈值  $\beta_{ij}$  的选取过于绝对，而且依赖于经验，这显然不适应瞬息万变的实际情况，易造成最终融合结果受主观因素的影响过大。由定义可知， $d_{ij}$  越靠近  $\beta_{ij}$ ，该距离涉及的传感器  $i$  被传感器  $j$  支持与否的判断越模糊，只有远离  $\beta_{ij}$  时才能清晰地说明支持或不支持。因此，文献[3, 4]考虑在阈值附近选择一个区间代替一个点的方法来确定关系矩阵。在阈值  $\beta_{ij}$  附近选择合适的区间  $[\beta_{ij}^L, \beta_{ij}^U]$ ，在区间  $[0, \beta_{ij}^L]$  和  $[\beta_{ij}^U, 1]$  上， $d_{ij}$  与  $\beta_{ij}$  的距离能够很明确地说明传感器之间的相互支持状况，因为在这两个区间段上  $r_{ij}$  分别取值 1 和 0；而在区间  $[\beta_{ij}^L, \beta_{ij}^U]$  上， $d_{ij}$  与  $\beta_{ij}$  的值相当接近，不能清楚地说明传感器之间的相互支持状况，此时可采用  $d_{ij}$  的严格单调下降函数来模糊地表示它们之间的支持程度，为确保  $r_{ij}$  随距离  $d_{ij}$  变化的稳定性，该函数应尽量具有一定的光滑性，且其值应介于 0~1 之间，并且经过点  $(\beta_{ij}^L, 1)$ 、 $(\beta_{ij}, 0.5)$  和  $(\beta_{ij}^U, 0)$ 。例如选取下述折线方程来表示区间  $[0, 1]$  上各段  $r_{ij}$  与  $d_{ij}$  的关系：

$$r_{ij} = \begin{cases} 1 & d_{ij} < \beta_{ij}^L \\ 1 - 0.5 \frac{d_{ij} - \beta_{ij}^L}{\beta_{ij}^L - \beta_{ij}} & d_{ij} \in [\beta_{ij}^L, \beta_{ij}] \\ 0.5 \frac{\beta_{ij}^U - d_{ij}}{\beta_{ij}^U - \beta_{ij}} & d_{ij} \in [\beta_{ij}, \beta_{ij}^U] \\ 0 & d_{ij} > \beta_{ij}^U \end{cases} \quad (8.9)$$

该关系折线如图 8.4 所示。




图 8.4 传感器相互支持状态与置信距离的关系折线

当然，也可以选择其他单调下降的曲线来表示这一模糊区间。

设在  $m$  个传感器对同一目标的观测融合集合中，最佳融合数为  $l$  ( $l \leq m$ )，为方便计，不妨设融合集为  $\{x_1, x_2, \dots, x_l\}$ ，应用极大似然估计法，容易得到：

$$\hat{\theta} = \sum_{i=1}^l \sigma_i^{-2} x_i / \sum_{j=1}^l \sigma_j^{-2} \quad (8.10)$$

$\hat{\theta}$  就是基于融合集合  $\{x_1, x_2, \dots, x_l\}$  获得的最优融合目标状态估计。

① 从式(8.5)和式(8.6)可以明确地看出,由于两传感器测量分布密度 $p_i(x|x_i)$ 和 $p_j(x|x_j)$ 不同,故置信距离测度 $A$ 与 $B$ 在数值上不同,因此这样定义的置信距离显然与通常距离定义中的对称性要求不一致,即不具有“距离”定义的所有性质。

② 从统计学的角度讲,当 $\sigma_i \neq \sigma_j$ 时, $|x_i - x_j|/\sigma_i$ 的直观意义可以理解成样本 $x_j$ 与 $x_i$ 在标准差 $\sigma_i$ 之下的加权距离(马氏距离),但是由于两者分布不同,因此其统计意义是不清楚的。

③ 在确定关系矩阵 $R$ 的过程中,阈值 $\beta_{ij}$ 的确定表现为经验性,这显然为应用带来额外的负担。

④ 在确定关系矩阵 $R$ 的过程中, $r_{ij}$ 的取值为0或1,因此,数据的一致性过分强调了数据的聚集性,而未考虑到数据的散布性。

⑤ 该方法仅解决了一维数据的一致性数据融合问题,无法推广到多维情形。

针对上述问题,文献[5-12]已提出了一些改进的一致性数据融合方法。如对式(8.1)和式(8.2)定义的置信距离测度改进为

$$d_{ij} = 2 \left| \int_{x_i}^{x_j} p_i(x|x_i) dx \right| \times 2 \left| \int_{x_j}^{x_i} p_j(x|x_j) dx \right|$$

或

$$d_{ji} = 2 \left| \int_{x_i}^{x_j} p_i(x|x_i) dx \right| + 2 \left| \int_{x_j}^{x_i} p_j(x|x_j) dx \right|$$

就能够实现置信距离的对称性。

下面介绍几种比较典型的对置信距离测度的改进方法,用于不同领域的多传感器测量数据的一致性判断、剔除和融合处理。

## 8.2 基于分位数的离异值剔除方法

多传感器数据融合精度在很大程度上取决于测量的准确性,而实践中并不能保证每个传感器测量都是准确的,即传感器在测量中由于某种原因可能产生错误或具有较大偏差的测量,这些测量称为离异值(或野值、飞点),这些传感器测量参与融合势必会影响融合的精度。因此,在对多传感器的测量进行融合之前,应先对传感器测量进行一致性或相融性检验,对一致性或相融性程度好的测量进行融合,才能提高融合数据的精度。为了减少数据一致性判断对传感器精度的依赖性,利用数据分析中的分布图方法,采用加宽中位数、四分位数、四分位数的离散度及离异值截断点等算法确定测量数据集中的离异值<sup>[13-18]</sup>,并予以滤除。

### 8.2.1 一维情形

假定多传感器测量系统的测量值为 $x_1, x_2, \dots, x_n$ ,其次序统计量为 $x_{(1)}, x_{(2)}, \dots, x_{(n)}$ (即 $x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}$ )。其中, $x_{(1)}$ 和 $x_{(n)}$ 分别是该组数据的下、上极值。

**定义1** 中位数:若 $n$ 是奇数,中位数就是中心的次序统计量;而如果 $n$ 是偶数,中位

**定义 1** 中位数：若  $n$  是奇数，中位数就是中心的次序统计量；而如果  $n$  是偶数，中位数是与中心相邻的两个次序统计量的平均值。

根据定义 1，记该组测量值的中位数为  $x_M$ ，则有：

$$x_M = \begin{cases} x_{[(n+1)/2]} & n = 2k + 1 \\ (x_{(n/2)} + x_{(n/2+1)}) / 2 & n = 2k \end{cases} \quad (8.11)$$

**定义 2** 上四分位数  $F_u$ ：全部观测值中仅有四分之一的观测值比它大的一个值；下四分位数  $F_l$  是指全部观测值中仅有四分之一的观测值比它小的一个值。

根据定义 2 可知，上四分位数  $F_u$  是测量数据区间  $[x_M, x_{(n)}]$  的中位数；而下四分位数  $F_l$  是测量数据区间  $[x_{(1)}, x_M]$  的中位数。

**定义 3** 四分位数间距（或散度） $dF$ ：上四分位数与下四分位数之差，该间距中包括了全部观测值的一半，其数值越大，说明数据分散程度越大；反之，说明分散程度越小。

$$dF = F_u - F_l \quad (8.12)$$

**定义 4** 加宽中位数<sup>[16,17]</sup>：将中位数的位置从一个中心加宽（扩展）到相邻对称的多个中心数据点，又称为多中心平均或加权平均中位数。若  $n$  是奇数，当  $5 \leq n \leq 11$  时，加宽中位数是三个中心的次序统计量的平均；当  $n \geq 13$  时，它是五个中心的次序统计量的平均。若  $n$  是偶数，当  $5 \leq n \leq 12$  时，加宽中位数是四个中心的次序统计量的加权平均，权重分别是  $1/6, 1/3, 1/3, 1/6$ ；当  $n \geq 13$  时，它是六个中心的次序统计量的加权平均，其中中间四个的权重是  $1/5$ ，两边缘的权重是  $1/10$ 。

根据定义 4，记该组测量值的加宽中位数为  $M_p$ ，其确定方法如下：

若  $n$  为奇数， $5 \leq n \leq 11$ ，则加宽中位数  $M_p$  取 3 个中心的次序统计量的平均值：

$$M_p = \frac{1}{3} (x_{(\frac{n-1}{2})} + x_{(\frac{n+1}{2})} + x_{(\frac{n+3}{2})})$$

若  $n \geq 13$ ，则  $M_p$  取 5 个中心的次序统计量的平均值：

$$M_p = \frac{1}{5} (x_{(\frac{n-3}{2})} + x_{(\frac{n-1}{2})} + x_{(\frac{n+1}{2})} + x_{(\frac{n+3}{2})} + x_{(\frac{n+5}{2})})$$

若  $n$  为偶数， $6 \leq n \leq 12$ ，则加宽中位数  $M_p$  取 4 个中心的次序统计量的加权平均值：

$$M_p = \frac{1}{6} x_{(\frac{n-2}{2})} + \frac{1}{3} x_{(\frac{n}{2})} + \frac{1}{3} x_{(\frac{n+2}{2})} + \frac{1}{6} x_{(\frac{n+4}{2})}$$

若  $n \geq 14$ ，则  $M_p$  取 6 个中心的次序统计量的加权平均值：

$$M_p = \frac{1}{10} x_{(\frac{n-4}{2})} + \frac{1}{5} x_{(\frac{n-2}{2})} + \frac{1}{5} x_{(\frac{n}{2})} + \frac{1}{5} x_{(\frac{n+2}{2})} + \frac{1}{5} x_{(\frac{n+4}{2})} + \frac{1}{10} x_{(\frac{n+6}{2})}$$

基于分位数的离异点滤除步骤如下：

① 确定该组测量值的加宽中位数  $M_p$ 。

② 确定相应的上、下四分位数  $F_u$ 、 $F_l$ ，其取值分别是区间  $[M_p, x_{(n)}]$  和  $[x_{(1)}, M_p]$  的加宽中位数，并据此计算两个四分位数间距（离散度）为

$$dF = F_u - F_l \quad (8.13)$$

③ 求取离异值上、下截断点  $\rho_1$  和  $\rho_2$ ，计算公式为

$$\rho_1 = F_l - \frac{\beta}{2} \cdot dF, \quad \rho_2 = F_u + \frac{\beta}{2} \cdot dF \quad (8.14)$$

其中，常数  $\beta$  可以根据系统的测量精度依经验决定，例如可取  $\beta = 1$ 。

④ 离异值滤除。位于区间  $[\rho_1, \rho_2]$  之外的传感器的测量作为离异值予以滤除，而位于区间  $[\rho_1, \rho_2]$  内的传感器测量作为有效数据送入融合集，在融合中心进行融合。

不难看出，此处的加宽中位数与传统分布图法中的中位数相比，保留了中位数对于离异值的稳健性，融合计算使用的  $[\rho_1, \rho_2]$  内的传感器数据已经通过一致性检测，具有较高的可靠性，因此能够改善目标状态的融合精度。由于一致性检验中的加宽中位数和四分位数离散度的选择与极值点的取值无关，仅取决于数据的分布位置，并且有效区间  $[\rho_1, \rho_2]$  与离异值的关系也不大，因此用分布图法进行传感器测量数据的一致性检验与其概率分布无关。

## 8.2.2 多维情形

假设  $N$  个传感器的测量数据分别为  $\mathbf{Z}_1, \mathbf{Z}_2, \dots, \mathbf{Z}_N$ ，皆为  $m$  维向量，测量向量  $\mathbf{Z}_i$  相应的欧氏范数值记为  $Y_i$ ，即

$$Y_i = \|\mathbf{Z}_i\| = \left( \sum_{j=1}^m \mathbf{Z}_{ij}^2 \right)^{1/2} \quad i = 1, 2, \dots, N \quad (8.15)$$

将  $Y_i$  按由小到大的顺序排列，不妨仍记为： $Y_1, Y_2, \dots, Y_N$ ，则此时  $Y_N$  和  $Y_1$  分别为该组测量向量欧氏范数的上、下极值，其中位数为

$$M = \begin{cases} Y_{\frac{N+1}{2}} & N \text{ 为奇数} \\ \frac{1}{2}(Y_{\frac{N}{2}+1} + Y_{\frac{N}{2}}) & N \text{ 为偶数} \end{cases}$$

相应的上、下四分位数  $F_u$  和  $F_l$  分别为区间  $[M, Y_N]$  和  $[Y_1, M]$  的中位数，四分位数离散度为

$$dF = F_u - F_l \quad (8.16)$$

若认为欧氏范数与中位数的距离大于  $\beta \times dF$  的测量  $\mathbf{Z}_i$  为离异值，即当  $|Y_i - M| > \beta dF$  时，判断  $\mathbf{Z}_i$  是无效数据，则可得到相应的离异值淘汰点（截断点）分别为

$$\rho_1 = F_l - \frac{\beta}{2} dF, \quad \rho_2 = F_u + \frac{\beta}{2} dF \quad (8.17)$$

其中， $\beta$  为常数（可取 2 或更大），凡位于区间  $[\rho_1, \rho_2]$  内的传感器数据被认为是有效的一致传感器测量向量，可以送入融合集，在融合中心参与融合。

这种方法由于  $M$  与  $dF$  的选择仅与数据的分布位置有关，而与极值点的大小无关，即有效区间的获得与需排除的离异值关系不大。所以用分布图法来获得一致传感器数据的方法具有鲁棒性。

无论是一维情形还是多维情形，在排除了离异值之后，对剩下的多传感器测量数据采用极大似然估计方法进行数据融合即可提高目标融合状态的精度。



### 8.3 基于模糊集理论的多传感器一致性数据融合

在传感器探测过程中,受各种因素的影响,传感器测量与真实目标状态之间存在误差,假设各有效测量值只含有随机误差,则真实目标状态位于所有有效测量数据附近的可能性更大一些。为方便工程实际应用,可以选用三角模糊隶属函数<sup>[19-21]</sup>作为有效测量源于真实目标状态的不确定性描述。

定义:一个模糊数(或模糊函数) $\tilde{N}$ 是定义在实数域 $R$ 上的正规凸模糊集,且满足以下条件:

- 存在唯一的点 $x_0 \in R$ ,具有隶属度 $\mu_{\tilde{N}}(x_0)=1$ ;
- 隶属函数 $\mu_{\tilde{N}}(x)$ 在 $x_0$ 点是左、右连续的。

$R$ 上的元素 $x$ 属于 $\tilde{N}$ 的隶属度一般表达式可以写为

$$\mu_{\tilde{N}}(x) = \begin{cases} L(x) & l \leq x \leq x_0 \\ R(x) & x_0 \leq x \leq r \end{cases} \quad (8.18)$$

式中, $L(x)$ 为增函数,在 $x_0$ 点右连续,且有 $0 \leq L(x) \leq 1$ ;  $R(x)$ 为减函数,在 $x_0$ 点左连续,且有 $0 \leq R(x) \leq 1$ 。

模糊函数的类型有很多种,比如常见的有三角形、梯形和高斯型等。具体采用何种类型的模糊函数需要与实际问题结合确定,原则是所选用的模糊隶属度函数应该具有一定的合理性且易于后续处理。

如果 $L(x)$ 和 $R(x)$ 均为线性函数,则 $\tilde{N}$ 被称为三角模糊函数,简记为 $\tilde{N} = (l, x_0, r)$ 。

在图 8.5 中,三角形底边中心是传感器的测量均值,宽度为测量数据的标准差的 4 倍。设在实际探测中,应用 $n$ 个传感器,且第 $i$ 个传感器对真实值 $A$ 进行了 $k$ 次测量,测量值分别为 $x_{i1}, x_{i2}, \dots, x_{ik}$ 。其均值为 $\bar{x}_i$ ,标准差为 $\sigma_i$ ,则该测量的模糊量 $A_i$ 可以表示为三个模糊位置点:

$$A_i = (a_{i1}, a_{i2}, a_{i3}) = (\bar{x}_i - 2\sigma_i, \bar{x}_i, \bar{x}_i + 2\sigma_i) \quad (8.19)$$

在实际多传感器融合过程中,不同测量的可靠性是不一样的,因此对不同的测量在融合过程中应该赋予不同权重。其中稳定性比较好,可靠性比较高的测量数据在融合时应该赋予更大的权重。从理论上讲,如果某测量值越接近于真实目标状态(真值),那么可以认为该数据稳定性与可靠性越好。根据模糊理论,可以利用模糊贴近度衡量测量值与被估计的目标状态 $x$ 的接近程度,并用来确定相应的融合权重,以产生更高精度的融合结果。




图 8.5 三角形模糊数

定义：设  $A_i, A_j$  是两个模糊量， $S = S(A_i, A_j)$ ，若  $S$  满足：

- $0 \leq S \leq 1$ ；
- $S(A_i, A_i) = 1$ ；
- $S(A_j, A_i) = S(A_i, A_j)$ ；
- 当且仅当  $A_i \cap A_j = \emptyset$  时， $S = S(A_i, A_j) = 0$ ；
- 当  $A_i \subset A_j \subset A_s$  时，有  $S(A_i, A_j) > S(A_i, A_s)$ 。

则称  $S$  为  $A_i$  和  $A_j$  的贴近度，也就是  $A_i$  和  $A_j$  的接近程度<sup>[5]</sup>。

模糊量之间贴近度的计算有多种方法，为了实现方便，采用模糊距离度量计算贴近度：

$$S(A_i, A_j) = \frac{1}{1 + d(A_i, A_j)} \quad (8.20)$$

式中模糊距离

$$d(A_i, A_j) = \frac{1}{6} |a_{i1} + 4a_{i2} + a_{i3} - a_{j1} - 4a_{j2} - a_{j3}| \quad (8.21)$$

其中， $a_{ik}, a_{jk}, k=1, 2, 3$  分别为模糊量  $A_i$  和  $A_j$  的三个模糊位置点。可以看出， $S(A_i, A_j)$  值越大表示  $A_i$  和  $A_j$  越贴近；若  $S(A_i, A_j) = 1$ ，则表示  $A_i$  和  $A_j$  完全相同；而若  $S(A_i, A_j) = 0$ ，则表示  $A_i$  和  $A_j$  完全不一致。据此可以得到  $n$  个传感器的贴近度矩阵  $\mathbf{S} = \{S(A_i, A_j)\}_{n \times n}$ 。

由于每个传感器可能受到  $n$  个传感器测量系统中其余  $n-1$  个传感器的支持，因此，可以令

$$r_i = \sum_{\substack{j=1 \\ j \neq i}}^n S(A_i, A_j) \quad (8.22)$$

$r_i$  表示传感器  $i$  与所有其他传感器测量的贴近度，即其余传感器对传感器  $i$  的总支持程度。通过对  $r_i$  进行归一化处理，可以得到各个传感器测量在融合中的相对权重为

$$w_i = \frac{r_i}{r_1 + r_2 + \cdots + r_n} \quad (8.23)$$

基于所得各传感器数据的相对权重，可以得到最终的目标状态的加权融合估计为

$$\hat{x} = \sum_{i=1}^n w_i x_i \quad (8.24)$$

基于模糊集理论的多传感器一致性数据融合方法并不判别和剔除测量集合中的离异点，而是计算每个模糊测量的贴近度并产生各传感器测量的相对权重，权重的大小体现了该测量的相容程度，即其在融合中所起作用的大小。该方法缺点是模糊化处理会丢失部分分布知识对权重系数的正面影响，从而导致融合精度下降。

## 8.4 基于统计距离矩阵特征值的一致性数据融合

多传感器在测量过程中由于多种因素的影响，测量数据中不可避免地存在不确定的外界扰动信息。针对此类问题，本节提出一种基于统计距离矩阵特征值的多传感器一致性数据融

合算法。

首先,考虑到测量向量的高维特征和各分量属性之间的联系,引入能够有效度量测量数据之间相似度的 Mahalanobis 距离(即偏差系数),表示两个传感器测量数据间的统计距离<sup>[23-26]</sup>:

$$d_{ij} = [z_i - z_j]^T [R_i + R_j]^{-1} [z_i - z_j] \quad (8.25)$$

为对这种用传感器测量数据间相似性表示的信息支持程度进行规范化,基于  $d_{ij}$  构建支持度函数  $\theta_{ij}$ ,其需要满足以下两个条件:

- ①  $\theta_{ij}$  与统计距离呈反比例关系;
- ②  $\theta_{ij} \in [0, 1]$ , 使数据处理能够利用模糊集理论中隶属函数的优点,从而避免测量信息一致性度量的绝对化。

基于以上考虑,支持度函数  $\theta_{ij}$  表达式可以选取如下形式:

$$\theta_{ij} = \frac{\max\{d_{ij}\}_{i,j=1}^N - d_{ij}}{\max\{d_{ij}\}_{i,j=1}^N} \quad (8.26)$$

式中,  $\max\{d_{ij}\}_{i,j=1}^N$  为两传感器测量数据间统计距离的最大值,当  $d_{ij}$  为该最大值时,  $\theta_{ij}$  的值为 0,即认为两个传感器测量数据无任何互补信息,或者说该两传感器无法相互支持;随着  $\theta_{ij}$  的增加,传感器测量数据间的支持程度逐渐增大。传感器测量对自身的置信距离  $d_{ii} = 0$ , 此时的  $\theta_{ii} = 1$ ,表示传感器测量数据对自身支持程度最强。考虑到  $\theta_{ij}$  仅仅实现了测量数据  $z_i$  和  $z_j$  之间信息支持程度的度量,为了有效度量  $z_i$  与测量系统中所有其他传感器测量的综合支持程度,在  $\theta_{ij}$  的基础上进一步构建包含所有两传感器测量信息间基于统计距离的支持矩阵(又称为统计支持矩阵):

$$\mathbf{S} = [\theta_{ij}]_{N \times N} \quad (8.27)$$

设  $\delta_i$  为  $z_i$  被系统中所有其他传感器测量综合支持程度的度量,取  $\delta_i = \sum_{j=1}^N b_j \theta_{ij}$ , 其中,  $\{b_j\}_{j=1}^N$  为一组非负实数,将其改写为矩阵形式:

$$\boldsymbol{\Theta} = \mathbf{S} \boldsymbol{\eta} \quad (8.28)$$

式中,  $\boldsymbol{\Theta} = [\delta_1, \delta_2, \dots, \delta_N]^T$ ,  $\boldsymbol{\eta} = [b_1, b_2, \dots, b_N]^T$ 。

由式(8.27)所示的统计支持矩阵  $\mathbf{S}$  的构建过程可知,  $\mathbf{S}$  是一个对角线元素全为 1 的正定对称矩阵,且该矩阵中的其他元素均为小于等于 1 的正数。根据统计支持矩阵  $\mathbf{S}$  中元素的这一特征,由佩龙—弗罗贝尼乌斯(Perron—Frobenius)定理可知:  $\mathbf{S}$  存在最大特征值  $\lambda > 0$ , 且仅有该特征值对应的特征向量  $\boldsymbol{\eta}$  的所有分量全为正数,满足  $\lambda \boldsymbol{\eta} = \mathbf{S} \boldsymbol{\eta}$ , 求解该方程可以确定特征向量  $\boldsymbol{\eta}$ 。结合式(8.28)和等式传递原理,于是有

$$\boldsymbol{\Theta} = \lambda \boldsymbol{\eta} \quad (8.29)$$

由于  $\lambda$  为大于 0 的实常数,因此,  $\boldsymbol{\Theta} \propto \boldsymbol{\eta}$ , 对  $\boldsymbol{\eta}$  中的元素进行归一化处理可以得到  $\bar{\boldsymbol{\eta}}$ , 其中第  $i$  个元素即可作为描述测量  $z_i$  被系统中所有其他测量综合支持程度的一致性权重  $w_i$ :

$$w_i = b_i / \sum_{j=1}^N b_j \quad (8.30)$$

在获得一致权重  $w_i$  之后, 被估计系统状态可以根据加权融合的方法获取:

$$\hat{x} = \sum_{i=1}^N w_i z_i$$

与现有数据处理方法相比, 上述基于统计支持矩阵特征值的多传感器一致性数据融合方法既能控制多传感器测量数据中不确定的干扰, 又能实现对多传感器测量信息的充分利用。其主要缺点是置信距离的计算仅利用了测量数据概率分布的数字特征信息。

## 8.5 基于置信距离的多传感器一致性数据融合

基于置信距离的多传感器一致性数据融合方法是在正态分布的假定下, 基于统计假设检验理论建立的置信距离模型提出的一种新的一致性数据融合方法<sup>[27-31]</sup>。

### 8.5.1 一维情形的置信距离

正态分布有如下性质:

如果随机向量  $X$ 、 $Y$  服从正态分布  $N(\mu_x, \sigma_x^2)$ 、 $N(\mu_y, \sigma_y^2)$ , 且两者相互独立, 则这两个随机向量之差  $X - Y$  服从正态分布  $N(\mu_x - \mu_y, \sigma_x^2 + \sigma_y^2)$ 。

这样一来, 当  $n$  个传感器组成的测量系统观测同一目标时, 若各传感器独立观测, 则有  $x_i - x_j \sim N(0, \sigma_i^2 + \sigma_j^2)$ ,  $i, j = 1, 2, \dots, n$ 。

关于两正态母体的总体均值之差的假设检验有如下结论<sup>[32]</sup>:

设两个正态总体  $\xi, \eta$  分别服从正态分布  $N(\mu_1, \sigma_1^2)$ 、 $N(\mu_2, \sigma_2^2)$ 。当方差  $\sigma_1^2, \sigma_2^2$  已知时, 关于均值差  $\mu_1 - \mu_2$  的检验 (双侧检验) 为

$$H_0: \mu_1 - \mu_2 = \delta$$

$$H_1: \mu_1 - \mu_2 \neq \delta$$

检验结论如下:

在置信水平为  $\alpha$  的情况下, 若有

$$\frac{|\xi - \eta - \delta|}{\sqrt{\sigma_1^2 + \sigma_2^2}} \geq k_{1-\alpha/2}$$

则拒绝零假设  $H_0$ 。式中,  $k_{1-\alpha/2}$  是标准正态分布置信水平为  $\alpha$  的上门限。

据此, 定义如下置信距离:

$$d_{ij} = P_r \left( |Z| \leq \frac{|x_i - x_j|}{\sqrt{\sigma_i^2 + \sigma_j^2}} \right) \quad (8.31)$$

式中,  $x_i, x_j$  分别表示第  $i, j$  个传感器的测量值;  $\sigma_i^2, \sigma_j^2$  为相应的测量误差方差;  $Z$  表示服从标准正态分布的随机变量。

可以看出, 式 (8.31) 的统计意义十分明确, 它是测量数据  $x_i$  与  $x_j$  之差  $|x_i - x_j|$  的置信概率。因此, 在此定义之下, 8.1 节所述的 Luo 算法中的阈值 (或门限值)  $\beta_{ij}$  的含义即置信概率, 根据需要可以取 0.75, 0.85, 0.90 和 0.95 等, 从而避免了主观性而获得了客观性的概率意义。

### 8.5.2 多维情形的置信距离

对于多维情形下的多传感器测量数据一致性判断也可以通过定义相应的置信距离来实现 [28,29]。

假设用  $N$  个传感器对同一目标进行观测, 测量模型为

$$z_i = x + v_i \quad i = 1, 2, \dots, N \quad (8.32)$$

式中,  $x \in R^n$  是待估的常值状态参数;  $z_i \in R^n$  是第  $i$  个传感器的测量值; 传感器  $i$  的测量噪声  $v_i$  服从均值为零、方差为  $\Sigma_i$  的正态分布, 即  $v_i \sim N(0, \Sigma_i)$ , 假定各传感器的测量噪声互不相关。另外, 假设在这  $N$  个传感器中大多数传感器都是可靠的, 也就是说, 只有少数几个传感器不可靠或含有疏失误差。

对于任意两个传感器  $i$  和  $j$ , 定义两者的测量值  $z_i$  和  $z_j$  之间的置信距离为

$$d_{ij} = P_r \{ \chi^2(n) \leq (z_i - z_j)^T (R_i + R_j)^{-1} (z_i - z_j) \} \quad i, j = 1, 2, \dots, N \quad (8.33)$$

式中,  $\chi^2(n)$  表示自由度为  $n$  的卡方随机变量, 故式 (8.33) 也表示一个置信概率。

同样可以看出置信概率  $d_{ij}$  的统计意义, 其值越小, 传感器  $i$  的测量值  $z_i$  与传感器  $j$  的测量值  $z_j$  之间的支持程度越高, 两者就越能一致地用于融合估计目标状态参数, 两者融合能使估计的常值参数的不确定性减小; 若  $d_{ij}$  值较大, 两者之间相互支持程度较低, 其中的一个可能含有疏失误差, 两者融合会使结果变得更差, 达不到提高精度的目的。因此,  $d_{ij}$  可以作为传感器  $i$  的测量值  $z_i$  与传感器  $j$  的测量值  $z_j$  之间的一致性度量。阈值 (门限值) 的大小可以根据卡方分布置信水平确定, 一般可选取 0.75, 0.85, 0.90 和 0.95 等。

对于  $N$  个传感器的情况, 以  $d_{ij}$  为元素的置信距离矩阵定义为

$$\mathbf{D} = (d_{ij})_{N \times N} \quad (8.34)$$

### 8.5.3 基于置信距离的一致性数据融合方法

基于置信距离的多传感器一致性数据融合的基本步骤如下:

① 确定用于一致性检验的置信概率阈值  $\varepsilon_{ij}$ 。

② 计算  $N$  个传感器测量数据两两之间的置信距离  $d_{ij}$ , 从而得到置信距离矩阵  $\mathbf{D}$ 。

③ 在置信距离矩阵  $\mathbf{D}$  的下三角阵中去除掉对角线上的元素, 并在余下的元素中搜索距离最小, 且不超过  $\varepsilon_{ij}$  的一对传感器  $p$  和  $q$ , 即:

$$d_{pq} = \min_{i>j} \{d_{ij}\} \quad d_{pq} \leq \varepsilon_{pq}$$

④ 对传感器  $p$  和  $q$  的测量值运用极大似然估计进行融合, 融合结果作为传感器  $p$  的新的测量值; 同时, 在当前参与融合的传感器组中, 删除编号为  $q$  的传感器 (因其测量已被融

入传感器  $p$  中), 而编号大于  $q$  的传感器编号都减 1, 测量值和方差维持不变, 于是得到传感器数目减 1 的新的参与数据融合的传感器组, 重新计算各传感器测量之间的置信距离, 并构造新的置信距离矩阵  $D$ 。

⑤ 重复③和④, 直到搜索不到置信距离最近且不超过阈值  $\varepsilon_{ij}$  的一对传感器, 此时置信距离矩阵  $D$  中仍然存在的、各传感器中含有原始传感器数目最多的一个传感器组的融合估计结果, 即为原始多传感器组测量数据在给定置信水平之下的最终一致性融合估计结果, 该传感器组中所含有的原始传感器即为最大相互支持的传感器连接组。而此时的置信距离矩阵中剩余的传感器 (无法搜索到与其距离最近且不超过置信阈值的传感器) 中通常含有过大的疏失测量误差而未参与融合。

基于置信距离的一致性数据融合方法的上述 5 个步骤实现流程如图 8.6 所示。

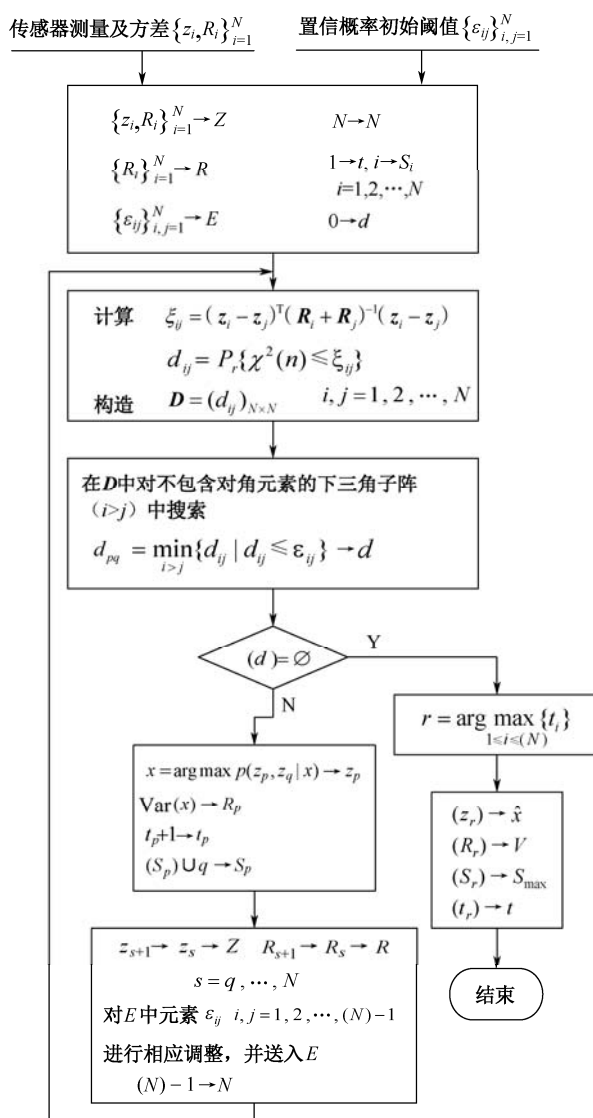


图 8.6 基于置信距离的一致性数据融合实现流程

图中,  $S_i$  为传感器  $i$  的工作单元, 用来保存传感器  $i$  及与其相继融合的各传感器序号,  $t_i$  为其中融入的传感器个数 ( $i=1, 2, \dots, N$ )。该流程图的输出结果  $S_{\max}$  即为  $N$  个传感器中最大相互支持的传感器连接组所包含的传感器序号,  $t$  为其中所含传感器个数,  $\hat{x}$  和  $V$  就是该连接组中各传感器测量一致融合的状态估计及误差协方差。

值得指出的是, 由置信距离的定义可知, 无论传感器的测量值中是否含有疏失误差, 传感器测量值到自身的统计距离都为 0, 即传感器对自身的支持程度永远是最高的, 所以利用传感器测量值到自身的统计距离无法衡量传感器测量值的一致性, 要检验传感器测量值的一致性, 只能通过不同传感器测量值之间的置信距离来判断, 这也就是在距离矩阵的下三角阵中搜索置信距离最近的元素时不考虑对角线上的元素的原因。

与前述的其他多传感器测量数据一致性融合方法相比, 基于置信距离的多传感器测量一致融合方法具有如下优势:

- 置信距离的统计意义更加明确, 因此其阈值确定方法更加客观;
- 融合过程与最大传感器连接组的搜索同步进行, 计算复杂度和计算量明显减小。

该一致性数据融合方法存在的不足是: 对于不同的传感器组, 如何选择置信概率阈值(或门限值)尚缺乏明确的优化理论指导。

## 8.6 基于测量精度分级的多传感器一致性数据融合

在文献[20,25]中阐述了根据传感器的测量精度及军事应用需求采用统计方法将传感器精度进行分级的测量融合方法。本节将这一思想应用于多传感器一致性融合之中, 提出了一种基于传感器测量精度分级的多传感器一致性数据融合的方法。

### 8.6.1 两个传感器测量数据偏差的概率比较

假设传感器 1 和传感器 2 同时观测同一目标, 其测量结果通常可以表示为两个独立的正态随机变量, 分别记为  $x$  和  $y$ , 在不影响结论的前提下, 不妨假定共同测量的目标待估参数为均值  $\mu_0$ , 则有  $x \sim N(\mu_0, \sigma_1^2)$  和  $y \sim N(\mu_0, \sigma_2^2)$ , 进一步假设  $\sigma_1^2 \leq \sigma_2^2$ , 即从测量可靠性的角度看, 传感器 1 比传感器 2 的测量精度更高。


首先从概率意义上讲, 对于直接测量待估参数的传感器, 其测量精度越高测量数据与待估参数(这里为  $\mu_0$ )之差的绝对值越小的可能性就越大, 于是, 这里给出的不同精度两传感器测量误差之间的关系概率可以表示如下:

$$P\{|x - \mu_0| \leq |y - \mu_0|\} \quad (8.35)$$

式中, 测量  $y$  的精度低于测量  $x$  的精度。记  $X = x - \mu_0$ ,  $Y = y - \mu_0$  分别表示两传感器的测量偏差, 则由假设可知,  $X \sim N(0, \sigma_1^2)$ ,  $Y \sim N(0, \sigma_2^2)$ 。式(8.35)变为

$$P\{|X| \leq |Y|\} \quad (8.36)$$

式(8.36)的几何意义如图 8.7 所示, 其中两传感器一维独立测量误差的联合区域中的阴影部分即为  $|X| \leq |Y|$  成立的区域。

图 8.7  $|X| < |Y|$  成立的几何区域

在上述两传感器独立测量且测量数据服从正态分布的假定下，由式 (8.36) 可以推得：

$$\begin{aligned}
 P\{|X| \leq |Y|\} &= \int_0^\infty \int_{-y}^y \frac{1}{2\pi\sigma_1\sigma_2} \exp\left\{-\frac{x^2}{2\sigma_1^2} - \frac{y^2}{2\sigma_2^2}\right\} dx dy + \\
 &\quad \int_{-\infty}^0 \int_y^{-y} \frac{1}{2\pi\sigma_1\sigma_2} \exp\left\{-\frac{x^2}{2\sigma_1^2} - \frac{y^2}{2\sigma_2^2}\right\} dx dy \\
 &= \int_0^\infty \frac{1}{\sqrt{2\pi}\sigma_2} \exp\left\{-\frac{y^2}{2\sigma_2^2}\right\} \int_{-y}^y \frac{1}{\sqrt{2\pi}\sigma_1} \exp\left\{-\frac{x^2}{2\sigma_1^2}\right\} dx dy + \\
 &\quad \int_{-\infty}^0 \frac{1}{\sqrt{2\pi}\sigma_2} \exp\left\{-\frac{y^2}{2\sigma_2^2}\right\} \int_y^{-y} \frac{1}{\sqrt{2\pi}\sigma_1} \exp\left\{-\frac{x^2}{2\sigma_1^2}\right\} dx dy \\
 &= \int_0^\infty \frac{1}{\sqrt{2\pi}\sigma_2} \exp\left\{-\frac{y^2}{2\sigma_2^2}\right\} \left[ \Phi\left(\frac{y}{\sigma_1}\right) - \Phi\left(-\frac{y}{\sigma_1}\right) \right] dy + \\
 &\quad \int_{-\infty}^0 \frac{1}{\sqrt{2\pi}\sigma_2} \exp\left\{-\frac{y^2}{2\sigma_2^2}\right\} \left[ \Phi\left(-\frac{y}{\sigma_1}\right) - \Phi\left(\frac{y}{\sigma_1}\right) \right] dy \\
 &= 2 \int_0^\infty \frac{1}{\sqrt{2\pi}\sigma_2} \exp\left\{-\frac{y^2}{2\sigma_2^2}\right\} \left[ 2\Phi\left(\frac{y}{\sigma_1}\right) - 1 \right] dy
 \end{aligned}$$

式中， $\Phi(\cdot)$  为标准正态分布函数。

进行变量代换： $z = y/\sigma_2$ ，并记  $\lambda = \sigma_2/\sigma_1$ ，可以得到如下结果：

$$P\{|X| \leq |Y|\} = 2 \int_0^\infty \frac{1}{\sqrt{2\pi}} \exp\left\{-\frac{z^2}{2}\right\} [2\Phi(\lambda z) - 1] dz \quad (8.37)$$

取  $\lambda = \sigma_2/\sigma_1 = 1, 1.5, 2.0, 2.5, 3.0, 3.5, 4.0, 4.5, 5.0, 5.5, 6.0$ ，利用数值积分软件不难得到式 (8.37) 表示的几何区域的相应概率值，如表 8.1 所示。

表 8.1 不同标准差比值  $\lambda$  下  $|X| < |Y|$  成立的概率

$\lambda$	1.5	2.0	2.5	3.0	3.5	4.0	4.5	5.0	5.5	6.0
$p$	0.626	0.705	0.758	0.795	0.823	0.844	0.861	0.874	0.885	0.895

根据表 8.1，把相应的计算结果绘制成如图 8.8 所示的曲线。






图 8.8 随  $\lambda = \sigma_2 / \sigma_1$  变化的  $P\{|X| \leq |Y|\}$  的曲线

从图 8.8 不难看出如下结论:传感器 1 与传感器 2 的测量精度相差越大(即  $\sigma_2 / \sigma_1$  越大),传感器 1 的测量比传感器 2 的测量更靠近真值的概率会更大,这也就意味着传感器 1 测量靠近真值的概率越大,如果两者的精度相差达到一定程度,如图 8.8 中  $\lambda$  超过 6 时,这几乎成为必然事件。

### 8.6.2 两传感器融合偏差与传感器测量偏差的概率比较

在 8.6.1 节诸假设下,基于极大似然估计的两传感器测量数据的融合偏差为

$$\mu = \frac{\sigma_2^2}{\sigma_1^2 + \sigma_2^2} X + \frac{\sigma_1^2}{\sigma_1^2 + \sigma_2^2} Y$$

记  $\lambda = \sigma_2 / \sigma_1$ , 则可以得到:

$$\mu = aX + bY \quad (8.38)$$

式中,  $a = \frac{\lambda^2}{1 + \lambda^2}$ ,  $b = \frac{1}{1 + \lambda^2}$ , 且有  $a + b = 1$ 。

两传感器测量融合偏差与精度最高的传感器测量偏差  $X$  的概率比较如下:

$$\begin{aligned} & P_r\{|X| \leq |aX + bY|\} \\ &= P_r\{X^2 \leq (aX + bY)^2\} \\ &= P_r\{X^2 - (aX + bY)^2 \leq 0\} \\ &= P_r\{(X + aX + bY)(X - aX - bY) \leq 0\} \\ &= P_r\{[(1+a)X + bY](bX - bY) \leq 0\} \\ &= P_r\{[(2\lambda^2 + 1)X + Y](X - Y) \leq 0\} \end{aligned} \quad (8.39)$$

类似于式 (8.37) 的推导过程, 通过积分变换可以得到:

$$P\{|X| \leq |aX + bY|\} = 2 \int_0^\infty \frac{1}{\sqrt{2\pi}} \exp\left\{-\frac{z^2}{2}\right\} \left[ \Phi(\lambda z) + \Phi\left(\frac{\lambda}{(1+2\lambda^2)} z\right) - 1 \right] dz \quad (8.40)$$

式中,  $\lambda = \sigma_2 / \sigma_1$ ,  $\Phi(\cdot)$  为标准正态概率分布函数。

$|X| \leq |aX + bY|$  成立的几何区域如图 8.9 中的阴影部分所示。




图 8.9  $|X| \leq |aX + bY|$  成立的几何区域

同样地，不难通过数值积分软件计算不同的  $\lambda = \sigma_2 / \sigma_1$  下式 (8.40) 表示的阴影区域的相应概率值，如表 8.2 所示。

表 8.2 不同标准差比值下  $|X| \leq |aX + bY|$  成立的概率

$\lambda$	1.0	1.5	2.0	2.5	3.0	3.5	4.0	4.5	5.0	5.5	6.0
$p$	0.352	0.398	0.422	0.437	0.447	0.455	0.460	0.465	0.468	0.471	0.474

把表 8.2 中的计算结果绘制成如图 8.10 所示的曲线。




图 8.10 随  $\lambda = \sigma_2 / \sigma_1$  变化的  $P_r\{|X| \leq |aX + bY|\}$  的曲线

由图 8.10 可以得到如下结论：随着两个传感器的测量统计精度（标准差）比值的增长，精度最高的传感器测量数据比两传感器测量融合结果更靠近真值的概率也相应地增大。当两个传感器的测量精度相差很大（即  $\lambda = \sigma_2 / \sigma_1$  接近于 6）时，精度最高的传感器测量数据比两传感器测量融合结果更靠近真值的概率并不小（0.47 左右），这说明通过融合提高目标状态估计精度的作用不明显；而当两个传感器测量精度十分相近（即  $\lambda = \sigma_2 / \sigma_1$  接近于 1）时，精度最高的传感器测量数据比融合结果更靠近真值的概率并不大（0.35 左右），这说明此时

通过融合提高目标状态估计精度的作用比较显著。

由此，我们可以得出如下融合原则：在进行多传感器数据一致性融合时，应优先考虑对精度比较接近的传感器数据进行融合，以快速提升融合结果的精度。

### 8.6.3 基于精度分级的多传感器一致性数据融合实现方法

目前已有的如 8.5.3 节描述的基于置信距离的一致性数据融合方法存在不足之处，主要包括：①最大传感器连接组的选择只考虑了传感器数量最多，并未考虑传感器的精度作用。这显然是不正确的，例如在三个传感器中，尽管两个精度很差的传感器数据十分一致，且与精度最好的传感器数据均不一致，这并不能说明这两个精度较差传感器一致连接组的数据融合结果比一个精度最好的传感器数据更好。②每个传感器数据只进行一次一致性判定处理，以确定其是否进入一个传感器连接组，而没有考虑各个传感器连接组融合处理结果的再次融合还会提升目标状态估计精度。这是现有一致性数据融合算法存在的本质缺陷。例如，多个传感器进行融合处理（如采用极大似然法）之后，其结果服从正态分布，且它的误差方差可能比参与融合的任何一個传感器数据的误差方差都要小，该融合结果很可能还会与其他传感器（或传感器连接组）的数据产生“新的一致性”，从而通过再一次一致性判定之后参与融合能够继续提高目标状态的融合估计精度。我们注意到，这种新一致性可能会在后续融合中持续产生正面效应，这一点在基于置信距离的一致性融合方法中被忽略了。

基于以上分析，本节提出如下基于分级的一致性数据融合方法，其基本步骤如下：

步骤 1（传感器分级）：对所有  $n$  个传感器按文献[1]9.3.2 节给出的有序样本最优聚集的 Fisher 方法进行传感器精度分组。假设共分为  $k$  组，各组包含的传感器数量为  $n_i$ ，且  $n_1$  中的传感器测量精度最高，而  $n_k$  中的传感器测量精度最低（ $i=1, 2, \dots, k$ ， $n_1 + n_2 + \dots + n_k = n$ ）。

步骤 2（同级融合）：对每个传感器组中的两两测量  $x_i$  和  $x_j$  按式（8.41）求出其置信距离：

$$d_{ij} = P_r \left( |Z| \leq \frac{|x_i - x_j|}{\sqrt{2} \min(\sigma_i, \sigma_j)} \right) \quad (8.41)$$

然后，给出置信水平  $\alpha$ （可供选择的有 0.01, 0.05, 0.1），确定置信阈值  $k_{1-\alpha/2}$ ，判定该传感器组中的各个传感器测量数据的一致性。若其中一个传感器测量至少与两个传感器的测量数据都通过了一致性检验，则优先选择与其置信距离最小的传感器测量进行融合，基于融合结果将被融合的两个传感器合并成一个“新传感器”，该过程类似于 8.5.3 节一致性数据融合步骤④；此步骤反复进行直至该传感器组中没有任何两个传感器的测量能够通过一致性检验和判定为止。该过程对所有传感器组精度分组重复进行直至完成所有  $k$  个传感器分组内测量的一致性融合处理。

步骤 3（逐级融合）：根据传感器测量精度分级水平，依次从精度最低的第  $k$  个传感器组的各同级融合结果与第  $k-1$  个传感器组的各同级融合结果进行再次一致性融合处理，获得更新后的第  $k-1$  个传感器组的各一致性融合结果；更新后的第  $k-1$  个传感器组的融合结果与第  $k-2$  个传感器组的各一致性融合结果进行再次一致性融合……直至更新后的第 2 个传

感器组的各一致性融合结果与第1个传感器组的各一致性融合结果进行再次一致性融合。

步骤4(全局融合): 经过步骤2与步骤3的融合处理之后, 最终获得了若干个通过一致性数据检验判定的传感器组的融合结果, 对这些传感器组的融合结果进行如下判定:

①以原始第1个传感器组为参照, 选择出包含原始第1个传感器组中各传感器的最终可选传感器连接组; ②在最终可选传感器连接组中, 选择融合精度最高的融合结果作为这 $n$ 个传感器测量的一致性全局融合结果。

### 8.6.4 计算案例

下面通过一个案例说明本节提出方法的优点。

设由10个传感器组成的探测系统测量某一目标特性参数(其真值为10), 获得测量数据如表8.3所示。

表8.3 10个传感器的观测值与精度指标

传感器序号	1	2	3	4	5	6	7	8	9	10
观测值 $x_i$	9.9545	9.8744	10.0827	10.3464	10.4006	9.9646	9.0638	10.1838	9.0565	9.0497
精度 $\sigma_i^2$	0.05	0.07	0.10	0.20	0.30	0.25	0.10	0.10	0.20	0.30

基于表8.3的10个传感器按精度分级的一致性数据融合步骤如下:

步骤1(按精度传感器分级): 基于表8.3对10个传感器根据其测量精度接近程度由高至低可以分为 $\{1, 2\}$ 、 $\{3, 7, 8\}$ 、 $\{4, 9\}$ 、 $\{6\}$ 和 $\{5, 10\}$ 等5个传感器组(见图8.11左部)。

步骤2(同级融合): 对各组内传感器数据进行同级融合处理, 取置信水平 $\alpha = 0.05$ , 即 $d_{ij}$ 阈值为0.95。

不难计算得到:

$$d_{12} = 0.2; d_{37} = 0.9773, d_{78} = 0.9833, d_{38} = 0.0909; d_{49} = 0.9586; d_{5,10} = 0.9186$$

按阈值判断, 传感器 $\{1\}$ 和 $\{2\}$ , 传感器 $\{3\}$ 和 $\{8\}$ , 传感器 $\{5\}$ 和 $\{10\}$ 可以进行同级融合(见图8.11右部)。




图8.11 传感器分级与同级融合

① 传感器 $\{1\}$ 和 $\{2\}$ 的融合结果记为 $x_{12}$ , 标准差记为 $\sigma_{12}$ , 并记为新传感器 $\{1-2\}$ :

$$x_{12} = 9.9211, \sigma_{12} = 0.1708$$

② 传感器 { 3 } 和 { 8 } 的融合结果记为  $x_{38}$ ，标准差记为  $\sigma_{38}$ ，并记为新传感器 { 3-8 }：

$$x_{38} = 10.1082, \quad \sigma_{38} = 0.2236$$

③ 传感器 { 5 } 和 { 10 } 的融合结果记为  $x_{5,10}$ ，标准差记为  $\sigma_{5,10}$ ，并记为新传感器 { 5-10 }：

$$x_{5,10} = 9.72516, \quad \sigma_{5,10} = 0.3873$$

步骤 3 (逐级融合)：对不同精度级别分组内的传感器数据自底向上逐级融合 (如图 8.12 所示)。

① 新传感器 { 5-10 } 与传感器 { 6 } 融合判定。

不难计算得到传感器 { 5-10 } 与传感器 { 6 } 的置信距离：

$$d_{5-10,6} = 0.338$$

按阈值判断，两者可以融合，融合结果记为  $x_{5,6,10}$ ，标准差记为  $\sigma_{5,6,10}$ ，并记为新传感器 { 5-6-10 }：

$$x_{5,6,10} = 9.8149, \quad \sigma_{5,6,10} = 0.3062$$

② 新传感器 { 5-6-10 } 与传感器 { 4 } 和传感器 { 9 } 的融合判定。

传感器 { 5-6-10 } 与传感器 { 4 } 和 { 9 } 分别的置信距离为

$$d_{5-6-10,4} = 0.338, \quad d_{5-6-10,9} = 0.9201$$

可见两者的距离均小于阈值 0.95，但是根据最近距离原则，应将传感器 { 4 } 与新传感器 { 5-6-10 } 进行融合处理得到：

$$x_{4,5,6,10} = 9.9845, \quad \sigma_{4,5,6,10} = 0.2526$$

由于新传感器 { 4-5-6-10 } 与传感器 { 9 } 的距离为

$$d_{4-5-6-10,9} = 0.9906$$

所以，两者不能进行融合处理。

③ 新传感器 { 4-5-6-10 } 和传感器 { 9 } 与新传感器 { 3-8 } 和传感器 { 7 } 的融合处理过程：

$$d_{4-5-6-10,3-8} = 0.3043, \quad d_{4-5-6-10,7} = 0.99, \quad d_{9,3-8} = 0.9991, \quad d_{9,7} = 0.013$$

按阈值判断，新传感器 { 4-5-6-10 } 与新传感器 { 3-8 }，传感器 { 9 } 与传感器 { 7 } 满足融合条件，可以融合处理得到：

$$x_{3,4,5,6,8,10} = 10.0539, \quad \sigma_{3,4,5,6,8,10} = 0.1674; \quad x_{7,9} = 9.0613, \quad \sigma_{7,9} = 0.2582$$

④ 新传感器 { 1-2 } 分别与新传感器 { 3-4-5-6-8-10 } 和新传感器 { 7-9 } 融合处理：

$$d_{3-4-5-6-8-10,1-2} = 0.42517, \quad d_{7-9,1-2} = 0.9996$$

按阈值判断，新传感器 { 1-2 } 与新传感器 { 3-4-5-6-8-10 } 可以融合，得到：

$$x_{1,2,3,4,5,6,8,10} = 9.9888, \quad \sigma_{1,2,3,4,5,6,8,10} = 0.1196$$

步骤 4 (全局融合)：由于最终得到 { 1, 2, 3, 4, 5, 6, 8, 10 } 和 { 7, 9 } 两个传感器组，且精度最高的原始第 1 个传感器组均在第一连接组内，因此，这 10 个传感器的全局一致性融合结果即为： $x_{1,2,3,4,5,6,8,10} = 9.9888$ ， $\sigma_{1,2,3,4,5,6,8,10} = 0.1196$ 。




图 8.12 不同层级的逐级融合过程

对该案例采用 8.5.3 节基于置信距离的一致性数据融合方法，按阈值判断得到置信距离（概率）矩阵  $D$  为

$$D = \begin{bmatrix} 0 & 0.2 & 0.3148 & 0.7847 & 0.8417 & 0.0254 & 0.9552 & 0.4292 & 0.9955 & 0.9958 \\ 0 & 0.4223 & 0.7928 & 0.8404 & 0.1905 & 0.9697 & 0.5118 & 0.9712 & 0.9725 \\ & 0 & 0.4445 & 0.5228 & 0.2083 & 0.9772 & 0.0909 & 0.9782 & 0.9791 \\ & & 0 & 0.06837 & 0.4539 & 0.9958 & 0.3655 & 0.9586 & 0.9597 \\ & & & 0 & 0.4626 & 0.9972 & 0.4493 & 0.9664 & 0.9188 \\ & & & & 0 & 0.9560 & 0.2948 & 0.8489 & 0.8042 \\ & & & & & 0 & 0.9833 & 0.0129 & 0.0251 \\ & & & & & & 0 & 0.9840 & 0.9846 \\ & & & & & & & 0 & 0.0086 \\ & & & & & & & & 0 \end{bmatrix}$$

从该置信距离矩阵的各元素出发，从阈值 0.95 判断，可以看出：

支持传感器 {1} 的有 6 个传感器，支持传感器 {2} 的有 6 个传感器，支持传感器 {3} 的有 6 个传感器，支持传感器 {4} 的有 6 个传感器，支持传感器 {5} 的有 7 个传感器，支持传感器 {6} 的有 8 个传感器，支持传感器 {7} 的有 2 个传感器，支持传感器 {8} 的有 6 个传感器，支持传感器 {9} 的有 3 个传感器，支持传感器 {10} 的有 4 个传感器。

如果以获得 6 个传感器测量支持为准则，则满足条件的原始传感器序号分别为 1, 2, 3, 4, 5, 6, 8，其融合结果为

$$x_{1,2,3,4,5,6,8} = 10.0358, \quad \sigma_{1,2,3,4,5,6,8} = 0.1225$$

该融合结果无论是真值估计还是标准差估计显然都不如本文提出的算法。

## 8.7 本章小结

本章给出了多传感器测量数据一致性的概念，并提出了一致性数据融合问题。针对传感器数据一致性度量与融合问题讨论了基于分位数分布图理论的离异值剔除方法、基于模糊集理论的一致性数据融合方法、基于统计距离和基于矩阵特征值的数据一致性度量方法，以及基于置信距离的多传感器一致性数据融合方法。本章分析了两传感器测量精度之比对融合效果的影响，得出“两传感器测量精度越接近，融合效果越显著”的结论，这对分析和确定融合准则具有重要的应用价值。在此基础上，本章提出了一种基于精度分级的多传感器数据融

合方法并通过仿真案例说明了该方法比已有的一致性数据融合方法具有较显著的优势。

## 参考文献

- [1] 赵宗贵, 熊朝华, 王珂, 等. 信息融合概念、方法与应用[M]. 北京: 国防工业出版社, 2012, 323-359.
- [2] 赵宗贵, 刁联旺, 李君灵, 等. 信息融合工程实践—技术与方法[M]. 北京: 国防工业出版社, 2015, 234-236.
- [3] 焦竹青, 熊伟丽. 基于信任度的多传感器数据融合及其应用[J]. 东南大学学报(自然科学版), 2008, 38(01): 253-257.
- [4] Luo R C, Lin M, Scherp R S. Dynamic Multi—Sensor Data Fusion System for Intelligent Robots[J]. IEEE Journal of Robotics and Automation, 1988, 4(4): 386-396.
- [5] 王华, 邓军, 王连华, 等. 改进的一致性数据融合算法及其应用[J]. 中国矿业大学学报, 2009, 38(04): 590-594.
- [6] 陈天璐, 阙沛文. 信息融合多传感器可信度的确定方法及应用[J]. 测试技术学报, 2005, 1(51): 61-64.
- [7] 孙皓莹, 蒋静坪. 基于参数估计的多传感器数据融合[J]. 传感器技术, 1995, 29(05): 32-27.
- [8] 廖惜春, 丘敏. 基于参数估计的多传感器数据融合算法研究[J]. 传感技术学报, 2007, 20(01): 193-197.
- [9] 胡振涛, 刘先省. 一种改进的一致性数据融合方法[J]. 传感器技术, 2005, 24(8): 65-67.
- [10] 王江萍, 沈力翔. 信息融合中多传感器测量一致性检验及其应用[J]. 石油机械, 1997, 25(11): 25-29.
- [11] 陈忠德, 蒋静坪. 一致性多传感器数据融合方法的改进[J]. 传感器技术, 1995, 14(5): 52-55.
- [12] 付春玲, 宫德龙, 李捷. 量测不确定下多传感器一致性数据融合算法[J]. 传感器与微系统, 2013, 32(07): 113-117.
- [13] 涂国平. 多传感器数据融合的稳健处理方法[J]. 数据采集与处理, 1998, 13(1): 85-87.
- [14] 金建华, 杨叔子. 油管壁厚测量数据的一致性加权融合估计算法[J]. 仪表技术与传感器, 2002, 11: 43-46.
- [15] 王昕, 张合. 一致性多传感器数据融合技术在引信信息融合中的应用[J]. 兵工学报, 2005, 26(5): 706-708.
- [16] Hoaglin D C, Mosteller F, Tukey J W. 探索性数据分析[M]. 陈忠琰, 郭德媛译. 北京: 中国统计出版社, 1998.
- [17] 岳元龙, 左信, 罗雄麟. 提高测量可靠性的多传感器数据融合有偏估计方法[J]. 自动化学报, 2014, 40(9): 1843-1852.
- [18] 薛飞, 杨友良, 董福涛. 基于多传感器融合算法的 CCD 测温系统设计[J]. 仪表技术与传感器, 2014, 8: 88-91.
- [19] 王婷杰, 施惠昌. 一种基于模糊理论的一致性数据融合方法[J]. 传感器技术, 1999, 18(6): 50-53.
- [20] 张璨, 张利, 刘征宇. 基于支撑裕的一致性多传感器融合算法[J]. 电子测量与仪器学报, 2010, 8(24): 711-715.
- [21] 李时. 一种多传感器温度数据动态融合方法[J]. 科技通报, 2015, 31(8): 146-170.

- [22] 梁小宇, 刘新华. 基于组播树的改进一致性数据融合算法[J]. 华中师范大学学报(自然科学版), 2011, 9, 347-381.
- [23] Odeberg H. Distance Measures for Sensor Opinions[J]. Measurement Science and Technology, 1993, 4(8): 808-815.
- [24] 程建兴, 史仪凯. 动态加权的一致性多传感器数据融合算法[J]. 火力与指挥控制, 2008, 33(8): 75-78.
- [25] ZhangLan Zhao, XiaoRong Li. Interaction between Estimators and Estimation Criteria[C]. In Proc. 2005 International Conf. on Information Fusion, Philadelphia, PA, USA, July, 2005.
- [26] XiaoRong Li, ZhangLan Zhao. Evaluation of Estimation Algorithms, Part I: Incomprehensive Performance Measures[J]. IEEE Trans. Aerospace and Electronic Systems, 2006, 42(4): 1340-1358.
- [27] 万树平. 多传感器数据融合的概率权方法[J]. 传感器与微系统, 2009, 28(8): 12-15.
- [28] 刁联旺, 王常武. 多传感器一致性数据方法的改进与推广[J]. 系统工程与电子技术, 2002, 24(9): 60-63.
- [29] 段战胜, 韩崇昭, 陶唐飞. 基于最近统计距离的多传感器一致性数据融合[J]. 仪器仪表学报, 2005, 26(05): 478-492.
- [30] G V S Raju, Husheng Wang. Sensor data fusion using Pitman's closeness technique and complete linkage algorithm[C]. Proceedings of the 1994 IEEE international conference on multisensory fusion and integration for intelligent systems, Las Vegas, Nevada, 1994: 71-75.
- [31] 张品, 董为浩, 高大冬. 一种优化的贝叶斯估计多传感器数据融合方法[J]. 传感器技术, 2014, 27(5): 643-648.
- [32] 陈希孺. 高等数理统计学[M]. 合肥: 中国科学技术出版社, 1999.



# 第9章 分布式信息融合发展的理论 基础

## 9.1 引言

如所周知,在集中式信息融合结构中,典型的融合方式包括如下三种。

测量—测量融合 ( Measurement—Measurement Fusion, MMF ), 由于在状态估计中, 目标测量通常以位置点的形式出现, 故 MMF 又被称为点迹融合或点迹聚集, 融合结果用来生成目标航迹, 或滤除杂波以减少虚警率。

测量—航迹融合 ( Measurement—Track Fusion, MTF ), 在多目标检测环境中已生成了一些目标航迹的情况下, 将获得的新测量 ( 点迹 ) 与已生成的目标航迹进行关联和融合, 称为 MTF。MTF 用来改善成功关联航迹的精度减少虚警率, 或对该航迹进行延续; 若新测量与所有已生成航迹均不关联, 则作为孤立点迹积累起来; 也可对孤立点迹集合进行 MMF 过程, 生成新的目标航迹。

航迹—航迹融合 ( Track—Track Fusion, TTF 或  $T^2F$  ), 融合中心对各站点独立生成的目标局部航迹进行关联和融合 ( 聚集 ), 以生成目标全局航迹; 或局部航迹与已有全局航迹进行融合, 对全局航迹进行更新和延续, 以改善目标航迹精度、减少虚警率。对于与已有全局航迹皆不关联的局部航迹, 可作为单一站点航迹或作为全局备选航迹, 待下一周期局部航迹到来, 继续  $T^2F$  过程。

近三十年来, 随着传感器信号检测技术的发展, MMF 和 MTF 技术和方法在理论和实际应用中已日趋成熟。与此同时, 随着通信网络的发展, 利用互联网或专用网络连接物理上分散的传感器和处理站点日益成为现实。作为对这一发展趋势的响应, 人们正在将 MTF 技术应用到分布式感知领域。然而, 由于通信链路带宽的限制, 通常无法实时传输传感器原始测量, 于是, 研究重点开始转向传输目标航迹数据。航迹数据在内涵上包括目标状态估计及其估计误差协方差矩阵, 其信息量大大低于传感器原始测量数据。对于具有自主处理能力的探测站点, 如配备扩展卡尔曼滤波器的雷达就能提供局部航迹, 这为有限带宽信道的实时信息传输带来了可能性和更大的灵活性。因此, 在通信网络支撑的分布式感知系统中, 为实时获取目标信息, 人们将信息融合的研究重点转向  $T^2F$ , 即对各传感器或局部站点报知的局部航迹进行关联和融合。

然而,  $T^2F$  与 MTF 在技术上存在较大差别, 这使得无法采用与 MMF 和 MTF 同样的处理方法实现  $T^2F$  功能。我们注意到, 集中式融合中的 MMF 和 MTF 在理论和实践上通常基于两个假设。第一个假设是: 不同时刻的目标状态信息之间是统计独立的, 第二个假

设是：不同传感器或信息源提供的信息之间是统计独立的。这两个假设之下的集中式信息融合系统将不同信息源、不同时间的输入信息皆视为统计独立（分布式融合中称为非相关）信息而进行融合；当某些输入信息非统计独立时，则忽略其相关性。这使得统计独立成为迄今为止出现的各种集中式融合技术和方法的前提条件。

在分布式感知系统中，全局融合站点的输入信息通常是目标局部航迹。首先，每条局部航迹在时间上是相互依赖的，即同一局部（或传感器）站点不同时刻提供的目标航迹可能是相关的。这是由于每一时刻的局部航迹在（基于测量）递推滤波过程中，皆将其基于上一时刻的局部航迹的预测作为先验信息融入。全局站点在  $T^2F$  过程中也要将其上一时刻的全局航迹预测值作为全局融合的先验信息。这样一来，在分布式多连接融合结构（包括单连接无反馈层次结构）中，上游共用节点信息为下游节点重复使用，从而使得集中式融合系统中同一信源不同时刻输入信息的统计独立性在分布式融合系统中不再成立。对于在分布式系统中应用集中式融合已有的成熟技术和方法，目前已出现了一些研究成果，如本书第 4.3.2 节所描述的局部或全局航迹重启方法，仅基于上次传输或融合之后获取的新测量集合生成局部航迹，或每次全局融合不使用上次融合结果（预测值）作为先验信息。这在一定程度上去除了同一信源输入航迹的时间相关性，但这样做需要改变融合信息图，并且对于带有较强过程噪声的目标航迹，特别是当目标机动时，将以丧失全局航迹的连续性（和平稳性）为代价。本书第 6 章所描述的小航迹（tracklet）融合方法<sup>[1]</sup>在原理上与局部重启方法类似，但不改变融合信息图，而是采用等效测量或伪测量变换的方法（也称逆卡尔曼滤波），解除输入的局部航迹之间的相关性，将全局融合公式变换为集中式融合的形式，从而可以应用任何集中式融合技术和方法，但是当目标快速机动时，需要在某个与机动方向和机动量有关的时间窗上实现解相关，这会带来较大的计算负荷，此时尚无法有效使用该方法。

我们知道，一个分布式  $T^2F$  站点的信息源可能有 3 类：①传感器（跟踪）站点，基于自身测量信息生成目标局部航迹，是  $T^2F$  的主要信息源；②其他信息处理站点，生成多源信息融合航迹，也是  $T^2F$  信息源之一；③先验信息，主要指各局部站点的先验信息和  $T^2F$  站点自身的先验信息，包括先验航迹信息（含航迹的先验估计及其协方差，或航迹的先验统计分布密度）、先验共用信息（如共用过程噪声、共用站点信息）以及非统计独立状况信息（如输入信息的交叉协方差）。在情况②下，当两个信息处理站点接收同一传感器信息时，其生成的局部航迹作为  $T^2F$  站点的输入时，显然是相关的。在情况③下，由于先验信息无法完全获得或由于通信带宽限制无法送达，因此无法解除输入信息的相关性，这样， $T^2F$  输入信息通常是非统计独立的。这就使得集中式融合的第二个假设即不同信源的输入信息之间的统计独立性在分布式融合系统中无法满足。例如，在分布式融合多连接信息图中，某一上游节点的信息以多条路径传输到同一个下游节点，若不考虑传输时间延误，则产生该信息的多次重复使用。即便在无反馈的单链接层次结构中，也会产生信息重用性现象（详见本书 4.3 节）。信息重用引起的相关性会导致融合误差协方差增长，如果由于无法确知信息重用状况而忽略该现象，则融合误差协方差矩阵将是不真实的，从而产生虚假的“最优”航迹估计而无法应用<sup>[2]</sup>。

当前,基于网络的许多分布式  $T^2F$  设计方案都将已确知的先验知识尽可能融入预先设定的拓扑结构中,以尽量避免输入信息重复使用等因素引起的相关性。但这需要在方案中预先考虑一条信息在网络中的整个传输历程,对于随机输入的测量信息则需要考虑实时产生和传输信息谱系引起的通信带宽增长。当这些条件满足时,才能在一定程度上去除信息重复使用现象所产生的融合性能恶化效应。具体地说,为了做到这一点,每个网络节点在传输目标测量或局部航迹估计信息的同时,还需要采用适宜的元数据记录该节点信息,并纳入信息传输谱系之中,并将生成的信息谱系(含该节点信息)一起传输给下游节点。然而,网络中累积的元数据最后会大大超过测量点迹或航迹文档的容量。当然,这个问题可以通过一点一点询问来回避,但这要以显著增加的通信带宽为代价。更加实际的困难是,要使目前已经应用的大量传统网络接受统一的谱系约定或标准,并据此修改和改善已有应用网络,这无异于天方夜谭。

在多传感器多目标环境中,目前的  $T^2F$  技术和方法大体可分为两类。一类方法是通过航迹关联产生表示同一目标的局部航迹估计集合,然后对该集合元素进行融合,产生该目标全局航迹。单目标分布式状态融合估计的方法和技术已在本书第 6 章中进行了详细分析,其中重点介绍了分布式目标跟踪中的两个要点——航迹融合与航迹关联,并与集中式跟踪性能进行了比较。分布式  $T^2F$  的第二类方法是 R Mahler 于 2000 年首次提出的<sup>[3]</sup>,并被 D Clark 及其同事改进的基于随机有限集的基础理论<sup>[4-6]</sup>。文献[7]对该方法的描述如下:

① 将整个多传感器—多目标系统作为一个采用随机有限集表示的单一、展开的随机过程;

② 通常以某种多源多目标递推贝叶斯滤波形式构造问题的一个最优解;

③ 达到这一目的的一个方法是寻找对应的单传感器、单目标问题的一个最优解,然后将其扩展到多传感器多目标情况;

④ 由于这个最优解在计算上几乎是无法实现的,因此必须将其公式化为原则上的统计近似表达式,包括:

- 采用概率假设密度 (PHD) 滤波,将多目标过程近似为一个展开的泊松 (Poisson) 过程 (见文献[7]第 16 章);
- 采用基数概率假设密度 (CPHD) 滤波,将多目标过程近似为一个独立同分布聚类 (IIDC) 过程;
- 采用多贝努里 (Bernoulli) 滤波,将多目标过程近似为一个展开的多贝努里过程 (见文献[7]第 17 章)。

本章采用前两个近似方法来应对多源多目标航迹融合的挑战,主要解决下述 3 个问题:

① 独立源航迹的精确  $T^2F$  问题;

② 已知带有“重复计入”航迹的独立源航迹的精确  $T^2F$  问题;

③ 未知源相关性航迹的近似  $T^2F$  问题,使用协方差交集 (CI) 方法向多目标扩展。

这 3 个问题的难度逐一递增,对每个问题,都需要从形成一个通用的多源多目标  $T^2F$  方法开始,然后采用 CPHD 滤波和 PHD 滤波导出计算上易于实现的近似表达式。

这里需要强调说明, 分布式  $T^2F$  中的“相关性”的概念与集中式融合中的概念完全不同。在集中式信息融合中, 我们认为融合中输入信息在来源和时间上都是统计独立的; 因此“相关性”与“关联”的概念相同或近似相同(如将信号和数据级源于同一目标的判定过程用“关联”表示, 而将航迹或识别结论表示同一目标的判定过程用“相关”表示), 它们同为相应级别上融合的前提条件。但是在分布式融合中, 将集中式融合“关联”的概念扩展到判定级, 即表示在任意级别上确定信息是否来源于同一对象的判定过程。而“相关”或“不相关”的概念则表示各融合输入信息(如航迹)是否相互独立, 如在获取手段上是否相互依赖, 过程噪声(不确定性)是否统计独立等。各自独立获取的信息才是不相关或统计独立的。分布式系统中相关信息的融合需要采用与非相关(统计独立)信息融合不同的方法, 否则会出现信息“重复计入”的现象, 导致融合误差协方差增长, 产生隐式虚假的最优估计, 会与估计对象真值渐行渐远。

无论是传感器对目标或杂波的状态测量, 还是目标状态估计, 皆表现为随机变量或随机变化过程, 从加性模型角度上讲, 通常以确定性状态加随机噪声的形式出现。因此, 作为分布式目标状态估计的理论基础, 本章以随机分布和随机过程表示动态目标状态及其测量的变化, 并推广到多目标情况。不管目标状态服从哪种随机分布, 目标状态估计(如航迹估计)多以一阶矩(期望)和二阶矩(方差)为主要参数, 它们通常能够从所确定的随机分布密度中提取出来。因此, 一阶矩和二阶矩在本章所述诸方法中起着重要作用。

本章各节内容的安排遵照由浅入深、循序渐进的原则。第2节综述了迄今为止关于单目标  $T^2F$  的重要研究成果, 只是后面各节关于多目标分布式融合所需要的, 而不是全部。包括贝叶斯滤波基本原理, 基于独立数据源的  $T^2F$  及其向非独立数据源的扩展以及作为典型启发性(尝试性)方法的协方差交集(CI)  $T^2F$  方法和指数混合(XM)  $T^2F$  方法。第3节向读者介绍了随机有限集统计学的基本原理, 包括以随机集形式描述的多传感器多目标贝叶斯滤波模型和方法, 基于泛函微积分的多目标随机分布(泊松分布和独立同分布)下的计算方法以及作为随机集主要应用成果的概率假设密度(PHD)滤波和含有目标基数(即目标数量未知)的概率假设密度(CPHD)滤波方法。第4节介绍了第2节描述的主要单目标  $T^2F$  方法向多目标分布式融合的扩展。第5节给出了基于CPHD滤波和PHD滤波的分布式融合方法, 包括基于CPHD滤波和PHD滤波的独立跟踪源(数据源)和非独立(相关)跟踪源的  $T^2F$  近似方法, 以及基于CPHD滤波和PHD滤波的多目标指数混合(XM)融合方法。第6节给出了多目标  $T^2F$  实现案例, 重点描述了高斯混合PHD滤波及粒子CPHD/PHD滤波两种通用融合结构, 并给出了实现步骤。此外, 第6节还描述了多目标指数混合  $T^2F$  近似公式的计算方法, 并给出了高斯PHD的XMT<sup>2</sup>F和粒子滤波的XM—PHDT<sup>2</sup>F公式的计算方法。

## 9.2 单目标分布式融合概述

如前所述, 通过关联处理可以获得表示同一目标的局部航迹集合, 从而将多目标分布

式融合转化为单目标融合问题。本节舍弃航迹关联环节，综述关于单目标 T<sup>2</sup>F 的一些主要成果，这是后面各章节所描述的面向多目标环境的分布式融合方法所需要的。

### 9.2.1 单目标贝叶斯滤波

贝叶斯滤波假设面对的目标运动模型和传感器测量模型，通常以下述加性离散模型的形式出现：

$$\begin{aligned}\mathbf{x}_{k+1|k} &= \varphi(\mathbf{x}_k) + \mathbf{W}_k \\ \mathbf{z}_{k+1} &= \eta(\mathbf{x}_{k+1}) + \mathbf{V}_{k+1}\end{aligned}\quad (9.1)$$

式中， $\mathbf{x}_k$  是单目标  $t_k$  时刻离散状态， $\mathbf{x}_{k+1|k}$  表示状态  $\mathbf{x}$  从  $t_k$  时刻向  $t_{k+1}$  时刻的转移状态；确定性运动模型  $\varphi(\mathbf{x}_k) = \varphi(\mathbf{x})$  是非线性函数； $\mathbf{W}_k$  是零均值随机向量（置入状态噪声，通常由目标非规律运动或环境噪声引起）。在非确定性测量模型中， $\mathbf{z}_{k+1}$  是  $t_{k+1}$  时刻的目标测量， $\eta(\mathbf{x}_{k+1}) = \eta_{k+1}(\mathbf{x})$  是非线性函数， $\mathbf{V}_{k+1}$  是  $t_{k+1}$  时刻的零均值随机噪声向量（又称传感器测量噪声）。

由这两个模型就能够构建马尔可夫概率密度转移方程和条件似然函数计算公式：

$$f_{k+1|k}(\mathbf{x} | \mathbf{x}') = f_{\mathbf{W}_k}[\mathbf{x} - \varphi(\mathbf{x}')] \quad (9.2)$$

$$f_{k+1}(\mathbf{z} | \mathbf{x}) = f_{\mathbf{V}_{k+1}}[\mathbf{z} - \eta_{k+1}(\mathbf{x})] \quad (9.3)$$

式 (9.2) 和式 (9.3) 表示这两个密度函数分别等同于相应的动态噪声和测量噪声分布。

这样一来，单目标贝叶斯递推滤波就由预测方程（又称时间更新方程）和状态更新方程（又称为测量更新方程）定义为

$$f_{k+1|k}(\mathbf{x} | Z^k) = \int f_{k+1|k}(\mathbf{x} | \mathbf{x}') f_{k|k}(\mathbf{x}' | Z^k) d\mathbf{x}' \quad (9.4)$$

$$f_{k+1|k+1}(\mathbf{x} | Z^{k+1}) = \frac{f_{k+1}(\mathbf{z}_{k+1} | \mathbf{x}) f_{k+1|k}(\mathbf{x} | Z^k)}{f_{k+1}(\mathbf{z}_{k+1} | Z^k)} \quad (9.5)$$

式 (9.5) 中的贝叶斯归一化因子为

$$f_{k+1}(\mathbf{z}_{k+1} | Z^k) = \int f_{k+1}(\mathbf{z}_{k+1} | \mathbf{x}') f_{k+1|k}(\mathbf{x}' | Z^k) d\mathbf{x}' \quad (9.6)$$

式 (9.4) ~ 式 (9.6) 中， $\mathbf{x}$  是单目标连续状态， $Z^k$  表示累积测量  $\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_k$ ，是传感器在  $t_1, t_2, \dots, t_k$  时刻获得的测量序列。

基于上述诸式的单目标贝叶斯递推滤波是随测量的序贯到来，不断生成和逐一传播目标状态的贝叶斯后验分布的过程，如图 9.1 所示。




图 9.1 单目标贝叶斯滤波后验概率密度一步递推流程

上述单目标贝叶斯滤波公式可以应用到下述几种情况：

(1) 杂波环境单目标多传感器测量情况,可能产生多条局部航迹(真目标和假目标)。此时可以使用相应的最优多目标状态估计器,从贝叶斯滤波产生的各类航迹的后验分布密度  $f_{k+1|k+1}(\mathbf{x}|Z^{k+1})$  中,提取所关注的目标状态(位置、速度及属性信息)。例如,采用最大后验(MAP)估计器能够在一定程度上排除冗余和虚假航迹,确定最可能的目标状态:

$$\mathbf{x}_{k+1|k+1}^{\text{MAP}} = \arg \sup_{\mathbf{x}} f_{k+1|k+1}(\mathbf{x}|Z^{k+1}) \quad (9.7)$$

(2) 对于独立多传感器测量的单目标状态融合问题,可以基于多传感器测量,应用目标后验分布密度和条件似然函数来解决。设有  $s$  个传感器,在同一时刻对该目标的测量集合为  $Z: \mathbf{z}_1, \dots, \mathbf{z}_s$ , 基于贝叶斯滤波获得的似然函数分别为  $f_{k+1}^1(\mathbf{z}_1|\mathbf{x}), \dots, f_{k+1}^s(\mathbf{z}_s|\mathbf{x})$ 。于是,基于  $s$  个传感器独立测量的联合似然函数为

$$f_{k+1}(Z|\mathbf{x}) = f_{k+1}^1(\mathbf{z}_1|\mathbf{x}) \cdots f_{k+1}^s(\mathbf{z}_s|\mathbf{x}) \quad (9.8)$$

式(9.8)融合了  $s$  个传感器测量,由于各传感器测量噪声、模型模糊程度以及回波信号反映的目标状态(包括几何形状)可能不同,因此通常需要从上述基于独立多传感器测量的单目标后验(联合)分布中提取该目标状态(和属性)的后验估计信息。

(3) 当目标运动模型和传感器测量模型皆为高斯分布时,贝叶斯滤波退化为卡尔曼滤波。同样,多传感器贝叶斯滤波(传感器相互独立)退化为多传感器卡尔曼滤波。在这两种情况下,目标“航迹”的概念可以有下面几种解释:

① 表示目标状态  $\mathbf{x}$  的瞬时( $t_k$ 时刻)估计:  $\hat{\mathbf{x}}_{k|k} = E(\mathbf{x}_k | Z^k)$ ,  $Z^k = (\mathbf{z}_1, \dots, \mathbf{z}_k)$  为直到  $t_k$  时刻的测量序列;

② 表示直到  $t_k$  时刻的目标状态  $\mathbf{x}$  的估计序列  $(\hat{\mathbf{x}}_{1|1}, \hat{\mathbf{x}}_{2|2}, \dots, \hat{\mathbf{x}}_{k|k})$ , 其中,  $\hat{\mathbf{x}}_{i|i} = E(\mathbf{x}_i | Z^i)$ ,  $Z^i = (\mathbf{z}_1, \dots, \mathbf{z}_i)$ ,  $i = 1, 2, \dots, k$ ;

③ 表示目标状态  $\mathbf{x}$  的瞬时后验估计及其误差协方差矩阵  $(\hat{\mathbf{x}}_{k|k}, \mathbf{P}_{k|k})$ , 其中,  $\mathbf{P}_{k|k} = \text{cov}[\hat{\mathbf{x}}_{k|k} - \mathbf{x}_k, (\hat{\mathbf{x}}_{k|k} - \mathbf{x}_k)^T]$ ;

④ 表示直到  $t_k$  时刻的目标状态估计及其误差协方差矩阵序列:  $(\hat{\mathbf{x}}_{1|1}, \mathbf{P}_{1|1}; \hat{\mathbf{x}}_{2|2}, \mathbf{P}_{2|2}; \dots; \hat{\mathbf{x}}_{k|k}, \mathbf{P}_{k|k})$ ;

⑤ 从开发一个更为通用的 T<sup>2</sup>F 理论和方法出发,特定时刻  $t_k$  的目标估计“航迹”被认为是整个后验分布  $f_{k|k}(\mathbf{x}|Z^k)$ , 而不仅仅是从后验分布提取的状态估计  $\hat{\mathbf{x}}_{k|k}$  或  $(\hat{\mathbf{x}}_{k|k}, \mathbf{P}_{k|k})$ 。此时,为了方便记忆,通常隐蔽对测量的依赖而缩写为

$$f_{k|k}(\mathbf{x}) = f_{k|k}(\mathbf{x}|Z^k) \quad (9.9)$$

## 9.2.2 独立数据源的 T<sup>2</sup>F

假设有  $s$  个独立数据源跟踪同一目标,其中  $t_k$  时刻测量序列为

$$Z_k: \mathbf{Z}_k^1, \mathbf{Z}_k^2, \dots, \mathbf{Z}_k^s \quad k = 1, 2, \dots$$

第  $j$  个数据源的直到  $t_k$  时刻的测量序列为

$$\mathbf{Z}^j : \mathbf{Z}_1^j, \mathbf{Z}_2^j, \dots, \mathbf{Z}_k^j \quad j=1, 2, \dots, s$$

其中,  $\mathbf{Z}_l^j$  表示  $t_l$  时刻第  $j$  个数据源获得的测量。

每个数据源向 T<sup>2</sup>F 站点传输的并不是原始测量, 而是对原始测量进行贝叶斯滤波产生的下述局部统计分布:

① 第  $j$  个数据源随测量序贯到来, 不断更新的  $t_{k+1}$  时刻目标航迹状态局部后验概率密度为

$$f_{k+1|k+1}^j(\mathbf{x}) = f_{k+1|k+1}^j(\mathbf{x} | \mathbf{Z}_{k+1}^j) \quad j=1, 2, \dots, s$$

② 外推至  $t_{k+1}$  时刻的第  $j$  个数据源目标航迹状态局部预测概率密度为

$$f_{k+1|k}^j(\mathbf{x}) = f_{k+1|k}^j(\mathbf{x} | \mathbf{Z}_k^j) \quad j=1, 2, \dots, s$$

③ 第  $j$  个数据源第  $t_{k+1}$  时刻测量的局部条件似然函数 (或累积测量集合的局部条件似然函数) 为

$$f_{k+1}^j(\mathbf{Z}_{k+1} | \mathbf{x}) \text{ 或 } f_{k+1}^j(\mathbf{Z}_{k+1}^j | \mathbf{x}) \quad j=1, 2, \dots, s$$

分三种情况讨论 T<sup>2</sup>F 站点对  $t_{k+1}$  时刻获得的目标局部航迹统计分布进行全局融合的原理。

(1) 各数据源向 T<sup>2</sup>F 站点上报上述 3 个目标航迹统计分布密度。

由贝叶斯公式 (9.5) 可得:

$$f_{k+1|k+1}^j(\mathbf{x}) \propto f_{k+1}^j(\mathbf{Z}_{k+1}^j | \mathbf{x}) f_{k+1|k}^j(\mathbf{x})$$

于是

$$f_{k+1}^j(\mathbf{Z}_{k+1}^j | \mathbf{x}) \propto f_{k+1|k+1}^j(\mathbf{x}) / f_{k+1|k}^j(\mathbf{x}) \quad j=1, 2, \dots, s$$

由各数据源的独立性,  $t_{k+1}$  时刻各传感器测量的联合条件似然函数为

$$\begin{aligned} f_{k+1}(\mathbf{Z}_{k+1} | \mathbf{x}) &= f_{k+1}^1(\mathbf{Z}_{k+1}^1 | \mathbf{x}) \cdots f_{k+1}^s(\mathbf{Z}_{k+1}^s | \mathbf{x}) \\ &\propto \frac{f_{k+1|k+1}^1(\mathbf{x})}{f_{k+1|k}^1(\mathbf{x})} \cdots \frac{f_{k+1|k+1}^s(\mathbf{x})}{f_{k+1|k}^s(\mathbf{x})} \end{aligned}$$

将此式代入下述贝叶斯公式

$$f_{k+1|k+1}(\mathbf{x}) \propto f_{k+1}(\mathbf{Z}_{k+1} | \mathbf{x}) f_{k+1|k}(\mathbf{x})$$

右端, 可以得到目标状态的全局后验密度估计<sup>[2]</sup>为

$$f_{k+1|k+1}(\mathbf{x}) \propto \frac{f_{k+1|k+1}^1(\mathbf{x})}{f_{k+1|k}^1(\mathbf{x})} \cdots \frac{f_{k+1|k+1}^s(\mathbf{x})}{f_{k+1|k}^s(\mathbf{x})} f_{k+1|k}(\mathbf{x}) \quad (9.10)$$

比例常数为

$$K = \int \frac{f_{k+1|k+1}^1(\mathbf{x})}{f_{k+1|k}^1(\mathbf{x})} \cdots \frac{f_{k+1|k+1}^s(\mathbf{x})}{f_{k+1|k}^s(\mathbf{x})} f_{k+1|k}(\mathbf{x}) d\mathbf{x} \quad (9.11)$$

上述诸式中采用的简写函数为

$$\begin{aligned} f_{k+1|k+1}(\mathbf{x}) &= f_{k+1|k+1}(\mathbf{x} | Z^{k+1}) \\ f_{k+1|k}(\mathbf{x}) &= f_{k+1|k}(\mathbf{x} | Z^k) \\ f_{k+1|k+1}^j(\mathbf{x}) &= f_{k+1|k+1}^j(\mathbf{x} | Z^{k+1}) \quad j=1,2,\dots,s \\ f_{k+1|k}^j(\mathbf{x}) &= f_{k+1|k}^j(\mathbf{x} | Z^k) \quad j=1,2,\dots,s \end{aligned}$$

式(9.10)和式(9.11)就是  $s$  个独立同步测量数据源的目标局部航迹状态融合后验分布密度表达式,是应用贝叶斯公式基于各数据源的独立、同步测量假设导出的。对于各数据源传感器异步探测情况,各数据源目标航迹的采集时间  $t_1, t_2, \dots, t_k$  可以依各数据源提供的目标航迹统计分布到达 T<sup>2</sup>F 站点的时间排序确定,然后再按一定时间偏差准则确定各融合时刻,将各局部航迹聚集到各融合时刻附近。若某一  $t_l$  时刻附近有  $s_l (< s)$  个统计分布数据到达 T<sup>2</sup>F 站点,则式(9.10)仅使用这  $s_l$  个数据源提供的统计分布进行融合。

(2) 各数据源向 T<sup>2</sup>F 站点仅传送  $t_{k+1}$  时刻测量的似然函数和目标航迹预测后验分布密度。

各数据源传送的  $t_{k+1}$  时刻测量似然函数和预测密度分别为

$$f_{k+1}^j(Z_{k+1} | \mathbf{x}), f_{k+1|k}^j(\mathbf{x}) \quad j=1,2,\dots,s$$

此时, T<sup>2</sup>F 站点利用贝叶斯公式(9.5)可得到  $t_{k+1}$  时刻各数据源提供的局部航迹后验分布密度为

$$f_{k+1|k+1}^j(\mathbf{x}) \propto f_{k+1}^j(Z_{k+1} | \mathbf{x}) f_{k+1|k}^j(\mathbf{x}) \quad j=1,2,\dots,s$$

再由各数据源的独立性,  $f_{k+1}(Z_{k+1} | \mathbf{x}) = f_{k+1}^1(Z_{k+1} | \mathbf{x}) \cdots f_{k+1}^s(Z_{k+1} | \mathbf{x})$

可得:

$$\begin{aligned} f_{k+1|k+1}(\mathbf{x}) &\propto f_{k+1}(Z_{k+1} | \mathbf{x}) f_{k+1|k}(\mathbf{x}) \\ &\propto f_{k+1}^1(Z_{k+1} | \mathbf{x}) \cdots f_{k+1}^s(Z_{k+1} | \mathbf{x}) f_{k+1|k}(\mathbf{x}) \end{aligned} \quad (9.12)$$

(3) 各数据源向 T<sup>2</sup>F 站点仅传送目标航迹后验分布密度。

此时,式(9.10)无法成立,需要采取一些限制性假设以使融合站点能够构建各数据源的目标航迹预测密度。

第一种方法是假设所有数据源采用同一目标运动模型,于是各数据源的马尔可夫状态转移概率密度与 T<sup>2</sup>F 站点的马尔可夫融合状态转移概率密度相同,即

$$f_{k+1|k}^j(\mathbf{x} | \mathbf{x}') = f_{k+1|k}(\mathbf{x} | \mathbf{x}') \quad j=1,2,\dots,s$$

于是, T<sup>2</sup>F 站点可基于第  $j$  个数据源  $t_k$  时刻报来的状态后验分布密度

$f_{k|k}^j(\mathbf{x}) = f_{k|k}^j(\mathbf{x} | Z^k)$  按式(9.4)构建各数据源的目标航迹预测后验密度:

$$f_{k+1|k}^j(\mathbf{x}) = f_{k+1|k}^j(\mathbf{x} | Z^k) = \int f_{k+1|k}(\mathbf{x} | \mathbf{x}') f_{k|k}^j(\mathbf{x}') d\mathbf{x} \quad j=1,2,\dots,s \quad (9.13)$$



然后再应用式 (9.10)，以获得  $t_{k+1}$  时刻融合的目标状态后验分布密度。

第二种方法是在更多的约束条件下，可以假设  $t_{k+1}$  时刻各数据源目标航迹的局部预测密度分布与 T<sup>2</sup>F 站点航迹的全局预测密度相同，即

$$f_{k+1|k}^j(\mathbf{x}) = f_{k+1|k}(\mathbf{x}) \quad j=1,2,\dots,s$$

此时式 (9.10) 可简化为

$$f_{k+1|k+1}(\mathbf{x}) \propto f_{k+1|k+1}^1(\mathbf{x}) \cdots f_{k+1|k+1}^s(\mathbf{x}) f_{k+1|k}(\mathbf{x})^{1-s} \quad (9.14)$$

式 (9.14) 就是 “贝叶斯并联组合” (见文献[7]P137)。

### 9.2.3 非独立数据源的 T<sup>2</sup>F

在上一节独立数据源的情况下，假设每个数据源配置专用传感器，也就是说各数据源不共用传感器。其准确描述是，令

$Z_1^i, Z_2^i, \dots, Z_k^i$  表示第  $i$  个数据源的直到  $t_k$  时刻的测量集合；

$Z_1^j, Z_2^j, \dots, Z_k^j$  表示第  $j$  个数据源的直到  $t_k$  时刻的测量集合。

并且对所有时刻  $l$ ， $Z_l^i \cap Z_l^j = \emptyset$  ( $i \neq j$ )，表示各数据源独立获取目标信息。

如果在某时刻  $t_l$ ，对某些数据源  $i$  和  $j$  ( $i \neq j$ )，存在  $Z_l^i \cap Z_l^j \neq \emptyset$ ，则至少有些数据源共用一些传感器，即这些数据源不是完全独立的。于是，我们能够将上一节中的 T<sup>2</sup>F 站点基于  $s$  个独立数据源测量获得的  $t_{k+1}$  时刻局部目标航迹生成全局后验分布密度公式 (9.10) 推广至这里的非独立数据源情况，即在已知某些传感器的测量数据被重复计入多个数据源的情况下，获得  $t_{k+1}$  时刻的全局融合目标航迹状态概率密度估计。

定义  $Z_{k+1} = Z_{k+1}^1 \cup Z_{k+1}^2 \cup \dots \cup Z_{k+1}^s$  为  $s$  个非独立数据源的目标测量集合的并集，其中某些数据源共用某些传感器的测量。例如，3 个数据源  $D_{s_1}, D_{s_2}, D_{s_3}$  对 3 个传感器  $s_1, s_2, s_3$  的测量数据共用状况如图 9.2 所示。




图 9.2 数据源对传感器测量数据的共用状况

图 9.2 所示的结构中，传感器  $s_1, s_2, s_3$  在  $t_{k+1}$  时刻对某个目标的测量分别为  $z_1, z_2, z_3$ ，数据源  $D_{s_1}$  所获得的测量集合  $Z^1 = \{z_1, z_2\}$ ，数据源  $D_{s_2}$  所获得的测量集合  $Z^2 = \{z_1, z_2, z_3\}$ ，数据源  $D_{s_3}$  所获得的测量集合  $Z^3 = \{z_3\}$ 。

易见  ${}^1Z \cap {}^2Z = \{z_1, z_2\}$ ,  ${}^2Z \cap {}^3Z = \{z_3\}$ ,  ${}^1Z \cap {}^3Z = \emptyset$ , 即测量数据  $z_1, z_2$  为数据源  $D_{s_1}$  和  $D_{s_2}$  共用,  $z_3$  为  $D_{s_2}$  和  $D_{s_3}$  共用, 而  $D_{s_1}$  和  $D_{s_3}$  相互独立。

图 9.2 中所示的数据源  $D_{s_1}$  和  $D_{s_2}$  进一步将其获取的信息或融合生成的局部航迹报知给同一 T<sup>2</sup>F 站点 A, 则站点 A 在融合时对共用信息  $\{z_1, z_2\}$  使用 2 次。同样 T<sup>2</sup>F 站点 B 在融合时对  $z_3$  使用 2 次。图 9.2 所示的站点 A 和 B 的融合信息进一步汇聚到下游站点 C, 则站点 C 在融合时对  $\{z_1, z_2\}$  使用 3 次 (重复使用 2 次), 对  $z_3$  使用 2 次。众所周知, 非独立数据源 (又称相关数据源) 对获得的共用信息重复使用会导致融合误差协方差增长, 这是分布式融合所面对的必须解决的问题。

为了将基于独立数据源的 T<sup>2</sup>F 状态的全局后验分布估计式 (9.10) 推广至非独立数据源的情况, 我们对  $s$  个非独立数据源提供的测量集合并集进行分解, 使分解后的各子集相互独立 (交集为空), 为简单计, 省略时序下标, 即将  $t_{k+1}$  时刻的  $s$  个传感器数据源提供的测量集合表示为:  $Z = {}^1Z \cup {}^2Z \cup \dots \cup {}^sZ$ 。

令

${}^{12}Z = {}^2Z - ({}^1Z \cap {}^2Z)$  表示不包含在  ${}^1Z$  中的第 2 个数据源提供的测量;

${}^{13}Z = {}^3Z - [({}^1Z \cup {}^{12}Z) \cap {}^3Z]$  表示不包含在  ${}^1Z \cup {}^{12}Z$  中的第 3 个数据源提供的测量;

$\vdots$

${}^{1j}Z = {}^jZ - [({}^1Z \cup {}^{12}Z \cup {}^{13}Z \cup \dots \cup {}^{1,j-1}Z) \cap {}^jZ]$  表示不包含在  ${}^1Z \cup {}^{12}Z \cup {}^{13}Z \cup \dots \cup {}^{1,j-1}Z$  中的第  $j$  ( $j \leq s$ ) 个

数据源提供的测量, 如图 9.3 所示。




图 9.3 非独立数据源测量集合的独立分解

从图 9.3 表示的测量集合  ${}^{12}Z, {}^{13}Z, {}^{14}Z$  所包含的范围可以看出,  ${}^1Z, {}^{12}Z, \dots, {}^{1s}Z$  是相互独立的 (它们之间无交集元素), 并且它们的并集覆盖了这  $s$  个数据源的测量集合并集  $Z$ 。这就实现了对  $s$  个非独立数据源所获得的数据集合  $Z = {}^1Z \cup {}^2Z \cup \dots \cup {}^sZ$  的独立分解。

对这  $s$  个数据源基于测量分解获得的相互独立测量集合  ${}^1Z, {}^{12}Z, \dots, {}^{1s}Z$  直接引用式 (9.10),

即可得到目标全局状态的后验估计公式为

$$f_{k+1|k+1}(\mathbf{x}) = \frac{f_{k+1|k+1}^1(\mathbf{x}|Z^{k+1})}{f_{k+1|k}^1(\mathbf{x}|Z^k)} \frac{f_{k+1|k+1}^2(\mathbf{x}|Z^{k+1})}{f_{k+1|k}^2(\mathbf{x}|Z^k)} \cdots \frac{f_{k+1|k+1}^s(\mathbf{x}|Z^{k+1})}{f_{k+1|k}^s(\mathbf{x}|Z^k)} f_{k+1|k}(\mathbf{x}) \quad (9.15)$$

式(9.15)去除了非独立测量集合  $Z = Z^1 \cup Z^2 \cup \cdots \cup Z^s$  中的重复信息, 其计算需要知道  $t_{k+1}$  时刻的每个数据源与前面数据源测量数据的共用情况, 以对  $t_{k+1}$  时刻测量集合  $Z_{k+1}$  进行独立分解, 计算  $f_{k+1|k+1}^j(\mathbf{x}|Z^{k+1})$  和  $f_{k+1|k}^j(\mathbf{x}|Z^k)$ ,  $j=2,3,\cdots,s$ , 并向全局站点传送。

下面我们再给出基于  $s$  个非独立数据源测量交集的全局航迹密度融合公式。令

$$Z = Z - Z^{(j)} \quad j = 2, \cdots, s \quad (9.16)$$

从图 9.3 又可看到:

$Z^{(2)}$  表示交集  $Z^1 \cap Z^2$ ;

$Z^{(3)}$  表示交集  $(Z^1 \cap Z^2) \cap Z^3$ ;

$\vdots$

$Z^{(j)}$  表示交集  $(Z^1 \cap Z^2 \cap Z^3 \cup \cdots \cap Z^{j-1}) \cap Z^j (j \leq s)$ 。

从式(9.16)可得  $Z^{1j} = Z - Z^{(j)}$ , 于是:

$$f_{k+1}^{1j}(Z_{k+1} | \mathbf{x}) = f_{k+1}^j(Z_{k+1} | \mathbf{x}) / f_{k+1}^{(j)}(Z_{k+1} | \mathbf{x}) \quad j = 2, \cdots, s$$

其表示从  $Z_{k+1}$  中去掉交集  $Z_{k+1}^{(j)}$  之后的  $Z_{k+1}^{1j}$  概率密度。再次援用  $t_{k+1}$  时刻独立数据源目标航迹的联合后验分布的似然函数表示形式(9.12), 可以得到:

$$\begin{aligned} f_{k+1|k+1}(\mathbf{x}) &\propto f_{k+1}^1(Z_{k+1} | \mathbf{x}) f_{k+1}^{12}(Z_{k+1} | \mathbf{x}) \cdots f_{k+1}^{1s}(Z_{k+1} | \mathbf{x}) f_{k+1|k}(\mathbf{x}) \\ &= f_{k+1}^1(Z_{k+1} | \mathbf{x}) \frac{f_{k+1}^2(Z_{k+1} | \mathbf{x})}{f_{k+1}^{(2)}(Z_{k+1} | \mathbf{x})} \cdots \frac{f_{k+1}^s(Z_{k+1} | \mathbf{x})}{f_{k+1}^{(s)}(Z_{k+1} | \mathbf{x})} f_{k+1|k}(\mathbf{x}) \end{aligned} \quad (9.17)$$

由条件概率公式  $P(\mathbf{z} | \mathbf{x}) = P(\mathbf{x} | \mathbf{z})P(\mathbf{z}) / P(\mathbf{x})$ , 可以得到:

$$\frac{f_{k+1}^j(Z_{k+1} | \mathbf{x})}{f_{k+1}^{(j)}(Z_{k+1} | \mathbf{x})} = \frac{f_{k+1|k+1}^j(\mathbf{x} | Z_{k+1}^j) f_{k+1}^j(Z_{k+1}^j)}{f_{k+1|k+1}^{(j)}(\mathbf{x} | Z_{k+1}^{(j)}) f_{k+1}^{(j)}(Z_{k+1}^{(j)})} \propto \frac{f_{k+1|k+1}^j(\mathbf{x} | Z_{k+1}^j)}{f_{k+1|k+1}^{(j)}(\mathbf{x} | Z_{k+1}^{(j)})} \quad j = 2, \cdots, s$$

这里视  $t_{k+1}$  时刻测量  $Z_{k+1}^j$  和交集  $Z_{k+1}^{(j)}$  的概率密度  $f_{k+1}^j(Z_{k+1}^j)$ 、 $f_{k+1}^{(j)}(Z_{k+1}^{(j)})$  为已知的测量分布。

我们再注意  $P(\mathbf{x} | Z^{k+1}) = P(\mathbf{x} | Z_{k+1}, \hat{\mathbf{x}}_k) = P(\mathbf{x}, \hat{\mathbf{x}}_k | Z_{k+1}) / P(\hat{\mathbf{x}}_k) \propto P(\mathbf{x} | Z_{k+1})$ , 这里  $P(\hat{\mathbf{x}}_k)$  为已知量, 并且  $\hat{\mathbf{x}}_k$  与  $Z_{k+1}$  无关。于是得到:

$$\frac{f_{k+1}^j(Z_{k+1}^j | \mathbf{x})}{f_{k+1}^{(j)}(Z_{k+1}^j | \mathbf{x})} \propto \frac{f_{k+1|k+1}^j(\mathbf{x} | Z_{k+1}^j)}{f_{k+1|k+1}^{(j)}(\mathbf{x} | Z_{k+1}^j)} \quad j=2, \dots, s$$

由于多数据源交集是确定性的, 故可视  $t_{k+1}$  时刻基于交集信息  $Z_{k+1}^{(j)}$  的状态估计与基于交集  $Z_k^{(j)}$  的预测状态相同, 于是得到:

$$\begin{aligned} \frac{f_{k+1}^j(Z_{k+1}^j | \mathbf{x})}{f_{k+1}^{(j)}(Z_{k+1}^j | \mathbf{x})} &\propto \frac{f_{k+1|k+1}^j(\mathbf{x} | Z_{k+1}^j)}{f_{k+1|k+1}^{(j)}(\mathbf{x} | Z_{k+1}^j)} \frac{f_{k+1|k+1}^j(\mathbf{x} | Z_{k+1}^j)}{f_{k+1|k+1}^{(j)}(\mathbf{x} | Z_{k+1}^j)} \\ &= f_{k+1|k+1}^j(\mathbf{x} | Z_{k+1}^j) / f_{k+1|k+1}^{(j)}(\mathbf{x} | Z_{k+1}^j) \end{aligned} \quad j=2, \dots, s \quad (9.18)$$

将式 (9.18) 代入式 (9.17) 得到:

$$\begin{aligned} f_{k+1|k+1}(\mathbf{x}) &\propto \frac{f_{k+1|k+1}^1(\mathbf{x})}{f_{k+1|k+1}^1(\mathbf{x} | Z)} \frac{f_{k+1|k+1}^2(\mathbf{x})}{f_{k+1|k+1}^2(\mathbf{x} | Z)} \dots \frac{f_{k+1|k+1}^s(\mathbf{x})}{f_{k+1|k+1}^s(\mathbf{x} | Z)} f_{k+1|k}(\mathbf{x}) \\ &\propto \frac{f_{k+1|k+1}^1(\mathbf{x})}{f_{k+1|k+1}^1(\mathbf{x} | Z)} \frac{f_{k+1|k+1}^2(\mathbf{x})}{f_{k+1|k+1}^2(\mathbf{x} | Z)} \dots \frac{f_{k+1|k+1}^s(\mathbf{x})}{f_{k+1|k+1}^s(\mathbf{x} | Z)} f_{k+1|k}(\mathbf{x}) \end{aligned} \quad (9.19)$$

式 (9.19) 就是基于  $s$  个非独立数据源局部航迹信息交集的全局融合航迹后验密度公式, 其需要知道每个融合时刻  $t_{k+1} (k=1, 2, \dots)$ , 第  $j (j=2, 3, \dots, s)$  个数据源与第  $1, 2, \dots, j-1$  个数据源共享哪些传感器测量以确定计入的重复测量信息交集  $Z_k^{(2)}, Z_k^{(3)}, \dots, Z_k^{(s)}$ , 并且该数据源除了向 T<sup>2</sup>F 站点传送  $f_{k+1|k+1}^j(\mathbf{x})$  外, 还必须传送  $f_{k+1|k+1}^j(\mathbf{x} | Z)$  或  $f_{k+1|k+1}^j(\mathbf{x} | Z_k^{(j)})$ 。随着传感器数量和局部站点 (数据源) 的增加, 考虑通信带宽和计算负荷, 基于该原理的计算实现变得更加复杂。

通常在使用中, 采用 (9.19) 中第一式更多, 当  $s=2$  时,

$$Z_{k+1}^{(2)} = Z_{k+1} - Z_{k+1}^{(1)} = Z_{k+1} \cap Z_{k+1}^{(2)}$$

此时,

$$\begin{aligned} f_{k+1|k+1}(\mathbf{x}) &\propto \frac{f_{k+1|k+1}^1(\mathbf{x}) f_{k+1|k+1}^2(\mathbf{x})}{f_{k+1|k+1}^1(\mathbf{x} | Z) f_{k+1|k+1}^2(\mathbf{x} | Z_{k+1}^{(2)})} f_{k+1|k}(\mathbf{x}) \\ &= \frac{f_{k+1|k+1}^1(\mathbf{x}) f_{k+1|k+1}^2(\mathbf{x})}{f_{k+1|k+1}^1(\mathbf{x} | Z) f_{k+1|k+1}^2(\mathbf{x} | Z_{k+1} \cap Z_{k+1}^{(2)})} f_{k+1|k}(\mathbf{x}) \end{aligned}$$

若再假设  $f_{k+1|k}^1(\mathbf{x}) = f_{k+1|k}(\mathbf{x})$ , 则

$$f_{k+1|k+1}(\mathbf{x}) \propto \frac{f_{k+1|k+1}^1(\mathbf{x}) f_{k+1|k+1}^2(\mathbf{x})}{f_{k+1|k+1}^1(\mathbf{x} | Z_{k+1} \cap Z_{k+1}^{(2)})} \quad (9.20)$$

式 (9.20) 是 Chong 等人在文献[2]中给出的。

### 9.2.4 协方差交集 (CI) 航迹融合

在前文中, 特别是 9.2.3 节, 需要具有充分的先验知识, 才能获得较精确的独立数据源 T<sup>2</sup>F 公式 (9.10) 和基于非独立数据源独立分解的 T<sup>2</sup>F 公式 (9.15) 或 (9.19)。然而, 在一般情况下, 常常无法获得足够的先验信息或无法有效利用先验信息。在无法得知数据源重用哪些传感器测量信息或具体的统计分布未知等先验知识较模糊的状态下, 如何解决 T<sup>2</sup>F 问题, 并且要使航迹融合的后验分布尽可能接近目标航迹的真实状态, Uhlmann 和 Julier 提出了协方差交集 (Covariance Intersection, CI) 航迹融合方法<sup>[8-10]</sup>。该方法是一种启发式方法, 是针对先验知识未知、模糊 (不准确) 或部分已知情况的一种加权平均方法, 通过调整和优化常数系数来改善融合航迹精度。CI 融合方法描述如下:

假设有两个跟踪源 (数据源) 同时观测到同一目标, 它们在某些时刻可能共用某些传感器的测量数据。在  $t_k$  时刻, 第一个跟踪源产生的目标航迹为  $(\mathbf{x}_{k|k}^0, \mathbf{P}_{k|k}^0)$ , 第二个跟踪源产生的该目标航迹为  $(\mathbf{x}_{k|k}^1, \mathbf{P}_{k|k}^1)$ 。为了使这两个部航迹的融合航迹  $(\hat{\mathbf{x}}_{k|k}, \mathbf{P}_{k|k})$  的误差在一定范围内, 即其模糊程度具有稳健 (鲁棒) 性,  $\hat{\mathbf{x}}_{k|k}$  的误差协方差矩阵  $\mathbf{P}_{k|k}$  应既不太大 (不太可信) 也不太小 (过于可信)。CI 融合将  $t_k$  时刻的融合航迹  $(\mathbf{x}_{k|k}^\omega, \mathbf{P}_{k|k}^\omega)$  定义为

$$\mathbf{P}_{k|k}^{-1} = (1-\omega)\mathbf{P}_{k|k}^{0-1} + \omega\mathbf{P}_{k|k}^{1-1} \quad (9.21)$$

$$\mathbf{P}_{k|k}^{-1} \mathbf{x}_{k|k}^\omega = (1-\omega)\mathbf{P}_{k|k}^{0-1} \mathbf{x}_{k|k}^0 + \omega\mathbf{P}_{k|k}^{1-1} \mathbf{x}_{k|k}^1 \quad (9.22)$$

其中,  $0 \leq \omega \leq 1$ , 协方差矩阵  $\mathbf{P}_{k|k}^\omega$  是正定对称矩阵 (不管  $\omega$  取何值)。当  $\omega = 0$  和  $\omega = 1$  时, 分别对应于第一条局部航迹  $(\mathbf{x}_{k|k}^0, \mathbf{P}_{k|k}^0)$  和第二条航迹  $(\mathbf{x}_{k|k}^1, \mathbf{P}_{k|k}^1)$ 。

假设

$$(\mathbf{x} - \mathbf{x}_{k|k}^0)^T \mathbf{P}_{k|k}^{0-1} (\mathbf{x} - \mathbf{x}_{k|k}^0) \leq \sigma^2 \quad (9.23)$$

$$(\mathbf{x} - \mathbf{x}_{k|k}^1)^T \mathbf{P}_{k|k}^{1-1} (\mathbf{x} - \mathbf{x}_{k|k}^1) \leq \sigma^2 \quad (9.24)$$

分别表示局部航迹  $(\mathbf{x}_{k|k}^0, \mathbf{P}_{k|k}^0)$  和  $(\mathbf{x}_{k|k}^1, \mathbf{P}_{k|k}^1)$  的估计误差标准差为  $\sigma$  的椭圆体, 则对于任何  $0 \leq \omega \leq 1$  和任何  $\sigma > 0$ , 融合航迹的误差椭圆体应满足:

$$(\mathbf{x} - \mathbf{x}_{k|k}^\omega)^T \mathbf{P}_{k|k}^{\omega-1} (\mathbf{x} - \mathbf{x}_{k|k}^\omega) \leq \sigma^2 \quad (9.25)$$

若式 (9.23) 和式 (9.24) 表示局部航迹误差的椭圆体面积分别设定为 A、B, 则式 (9.25) 表示融合航迹误差椭圆体的面积应小于 A、B 的面积, 即融合误差应小于每个局部航迹误差, 其形状与 A、B 的接近程度与  $\omega$  的取值有关。图 9.4 给出了局部误差椭圆 A、B 以及不同  $\omega$  取值下的融合航迹误差椭圆。

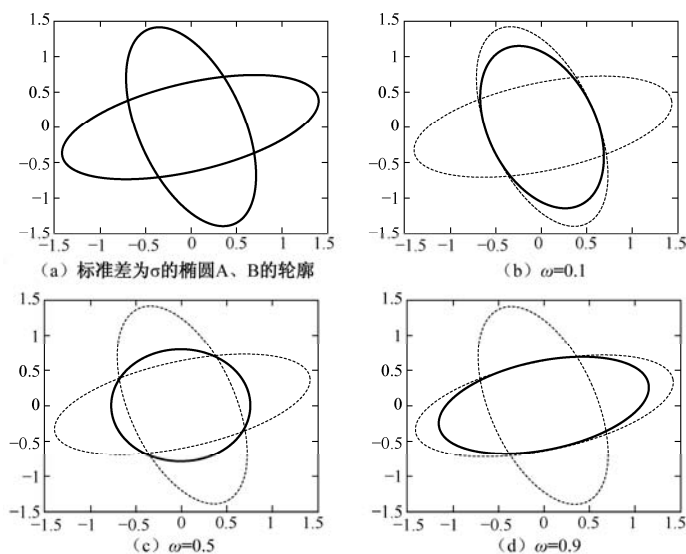
图 9.4 不同  $\omega$  取值下的融合航迹误差椭圆

图 9.4 (a) 给出了两局部航迹估计误差标准差为  $\sigma$  的椭圆 A、B 形状和大小, 图 9.4 (b) ~ (d) 分别给出了  $\omega$  取值为 0.1、0.5、0.9 时融合航迹误差标准差为  $\sigma$  的椭圆形状和大小 (图中的黑实曲线表示), 从中可以看出:

- 融合误差椭圆位于局部航迹误差椭圆 A、B 界定的范围  $[-1.5 \sim 1.5, -1.5 \sim 1.5]$  之内。
- 融合误差椭圆面积小于 A、B 的面积。
- 融合误差椭圆形状 (偏转角度) 随  $\omega$  取值变化, 如图 9.4 (b) ~ (d) 所示:  $\omega$  取 0.9, 则融合误差椭圆贴近并位于椭圆 B 内;  $\omega$  取 0.1, 则融合误差椭圆贴近并位于椭圆 A 内;  $\omega$  取 0.5, 则融合误差椭圆位于椭圆 A、B 的相交区域附近。
- 融合误差椭圆始终包含 A、B 的相交区域。

选择权系数  $\omega$  的原则是使得融合误差椭圆  $(\mathbf{x} - \mathbf{x}_{k|k})^T \mathbf{P}_{k|k}^{-1} (\mathbf{x} - \mathbf{x}_{k|k}) = \sigma^2$  的超体积尽可能小, 因此应尽可能与 A、B 的相交区域 (交集) 相拟合, 这就是该航迹融合命名为协方差交集 (CI) 的缘由。

鉴于融合误差椭圆超体积与融合误差协方差矩阵的单调关系, Uhlmann 和 Julier 提出使融合航迹误差协方差矩阵  $\mathbf{P}_{k|k}^\omega$  的迹或行列式达极小来选择  $\omega = \hat{\omega}^{[8-10]}$ , 即

$$\hat{\omega} = \arg \min_{\omega} \text{tr}(\mathbf{P}_{k|k}^\omega) \quad (9.26)$$

$$\text{或 } \hat{\omega} = \arg \min_{\omega} |\det(\mathbf{P}_{k|k}^\omega)| \quad (9.27)$$

其中,  $\mathbf{P}_{k|k}^\omega = \left[ (1-\omega) \mathbf{P}_{k|k}^{-1} + \omega \mathbf{P}_{k|k}^{-1} \right]^{-1}$ 。

Uhlmann 等人证明了在线性高斯情况下, 按式 (9.26) 或式 (9.27) 确定的  $\omega$  建立的 CI 融合公式 (9.21) 和 (9.22) 所获得的融合航迹近似于精确融合航迹, 该近似是无偏的, 并且其融合误差没有过度增大。

文献[11]提出一种更易于计算的“快速 CI”近似方法，其中权系数  $\omega$  按下式选取：

$$\omega = 1 - \frac{\det(\mathbf{P}_{k|k}^{-1} + \mathbf{P}_{k|k}^{-1}) - \det \mathbf{P}_{k|k}^{-1} + \det \mathbf{P}_{k|k}^{-1}}{2 \det(\mathbf{P}_{k|k}^{-1} + \mathbf{P}_{k|k}^{-1})} = \frac{1}{2} + \frac{\det \mathbf{P}_{k|k}^{-1} - \det \mathbf{P}_{k|k}^{-1}}{2 \det(\mathbf{P}_{k|k}^{-1} + \mathbf{P}_{k|k}^{-1})} \quad (9.28)$$

将式 (9.21) 和式 (9.22) 推广到多源 CI 问题中：

$$\mathbf{P}_{k|k}^{-1} = \omega_1 \mathbf{P}_{k|k}^{-1} + \omega_2 \mathbf{P}_{k|k}^{-1} + \cdots + \omega_n \mathbf{P}_{k|k}^{-1} \quad (9.29)$$

$$\mathbf{P}_{k|k}^{-1} \mathbf{x}_{k|k} = \omega_1 \mathbf{P}_{k|k}^{-1} \mathbf{x}_{k|k} + \omega_2 \mathbf{P}_{k|k}^{-1} \mathbf{x}_{k|k} + \cdots + \omega_n \mathbf{P}_{k|k}^{-1} \mathbf{x}_{k|k} \quad (9.30)$$

这里  $\omega_1 + \cdots + \omega_n = 1$ ，各权系数的近似选取公式为

$$\omega_i = \frac{\det \mathbf{P}_{k|k}^{-1} - \det \left( \mathbf{P}_{k|k}^{-1} - \mathbf{P}_{k|k}^{-1} \right) + \det \mathbf{P}_{k|k}^{-1}}{K} \quad i = 1, \cdots, n \quad (9.31)$$

式中， $\mathbf{P}_{k|k}^{-1} = \sum_{i=1}^n \mathbf{P}_{k|k}^{-1}$ ，归一化常数  $K$  为

$$n \cdot \det \mathbf{P}_{k|k}^{-1} + \sum_{j=1}^n \left[ \det \mathbf{P}_{k|k}^{-1} - \det \left( \mathbf{P}_{k|k}^{-1} - \mathbf{P}_{k|k}^{-1} \right) \right] \quad (9.32)$$

对协方差交集融合方法有效性的大量研究成果表明，对于任意分布（非线性非高斯分布）的局部航迹来说，仅考虑其一阶矩和二阶矩的 CI 方法产生的融合航迹估计可能并不太理想。也就是说，由于缺乏精确的先验知识，CI 融合的目标定位相比精确融合求解结果有一定差距。因此，在 CI 融合算法应用设计中必须面对被融合的航迹高度相关的恶劣情况，但即使如此，CI 融合算法仍难以取得满意的结果。

### 9.2.5 指数混合 (XM) 融合

根据上一节所述，CI 融合算法对于线性高斯分布的局部航迹融合效果还比较好，但对更一般的非线性、非高斯分布的局部航迹融合，CI 融合算法采用的直接对局部航迹误差协方差矩阵的加权平均算法通常达不到理想的融合效果。于是人们为了对 CI 融合算法进行更一般情况的扩展，尝试对局部航迹分布进行加权平均，而不仅对头二阶矩进行加权平均，以期获得理想的融合效果。

对具有线性高斯分布的两条局部航迹概率密度进行指数加权平均，可以得到下述融合公式<sup>[3]</sup>：

$$N_{\mathbf{P}_{k|k}}^{\omega}(\mathbf{x} - \mathbf{x}_{k|k}) = \frac{N_{\mathbf{P}_{k|k}}^0(\mathbf{x} - \mathbf{x}_{k|k})^{1-\omega} \cdot N_{\mathbf{P}_{k|k}}^1(\mathbf{x} - \mathbf{x}_{k|k})^{\omega}}{\int N_{\mathbf{P}_{k|k}}^0(\mathbf{y} - \mathbf{x}_{k|k})^{1-\omega} \cdot N_{\mathbf{P}_{k|k}}^1(\mathbf{y} - \mathbf{x}_{k|k})^{\omega} d\mathbf{y}} \quad (9.33)$$

式中， $N_{\mathbf{P}_{k|k}}^i(\mathbf{x} - \mathbf{x}_{k|k})$  是被融合的两条局部航迹  $(\mathbf{x}_{k|k}, \mathbf{P}_{k|k})$  的高斯分布密度 ( $i = 0, 1$ )，

$N_{\mathbf{P}_{k|k}}^{\omega}(\mathbf{x} - \mathbf{x}_{k|k})$  是融合航迹  $(\mathbf{x}_{k|k}, \mathbf{P}_{k|k})$  的高斯分布密度。文献[3]证明了对于  $0 \leq \omega \leq 1$ ，式

(9.33) 是正确的。这启发人们可以用概率密度指数加权平均来扩展一阶矩和二阶矩加权平均的 CI 融合方法。于是得到任意两跟踪源局部航迹分布密度的指数加权融合公式<sup>[12]</sup>如下:

$$f_{k+1|k+1}^{\omega}(\mathbf{x}) = \frac{f_{k+1|k+1}^0(\mathbf{x})^{1-\omega} \cdot f_{k+1|k+1}^1(\mathbf{x})^{\omega}}{\int f_{k+1|k+1}^0(\mathbf{y})^{1-\omega} \cdot f_{k+1|k+1}^1(\mathbf{y})^{\omega} d\mathbf{y}} \quad (9.34)$$

式 (9.34) 被称为任意两航迹分布密度的指数混合 (Exponential Mixture, XM) 融合公式。

XM 融合公式在理论上的合理性通过与 Chernoff 信息的相似性得到了证明。两个统计分布密度的 Chernoff 信息定义为

$$C(f_{k+1|k+1}^1, f_{k+1|k+1}^0) = \sup_{0 \leq \omega \leq 1} \left( -\ln \int f_{k+1|k+1}^0(\mathbf{x})^{1-\omega} \cdot f_{k+1|k+1}^1(\mathbf{x})^{\omega} d\mathbf{x} \right) \quad (9.35)$$

Chernoff 信息实际上是实现两个分布密度合成的公式, 即对两个分布信息或两个专家统计建议的对数合成公式<sup>[13]</sup>, 也可以用来合成多个分布或多个统计建议。面向两个线性高斯分布合成的 CI 融合方法, 显然是对数合成方法的一个特殊情况。因此, 式 (9.34) 描述的航迹 XM 融合模型<sup>[14,15]</sup>也被称为 Chernoff 融合模型<sup>[16]</sup>。文献[14]还提出了被融合的分布密度  $f_{k+1|k+1}^0(\mathbf{x})$  和  $f_{k+1|k+1}^1(\mathbf{x})$  是高斯混合型时, 计算 XM 合成分布  $f_{k+1|k+1}^{\omega}(\mathbf{x})$  的近似方法。

指数混合 (XM) 融合获得的统计密度具有两个重要的、吸引人的性质:

第一, 也是最重要的性质是, 对于带有重复计入航迹的情况, XM 融合密度计算形式不变, 与航迹重复计入次数无关<sup>[17]</sup>。也就是说, 假设被融合的航迹分布密度  $f_{k+1|k+1}^0(\mathbf{x})$  和  $f_{k+1|k+1}^1(\mathbf{x})$  含有 9.2.3 节所述上的重复计入航迹, 则  $f_{k+1|k+1}^{\omega}(\mathbf{x})$  只需要对该重复计入航迹融合一次, 而无须考虑其重复计入次数, 就能得到与式 (9.20) 同样的结果。

XM 融合密度  $f_{k+1|k+1}^{\omega}(\mathbf{x})$  的第二个重要的性质<sup>[9]</sup>是, 若  $0 \leq \omega \leq 1$ ,

- 对任意航迹状态  $\mathbf{x}$ , 有式 (9.36) 成立:

$$\min_{\mathbf{x}} \left\{ f_{k+1|k+1}^0(\mathbf{x}), f_{k+1|k+1}^1(\mathbf{x}) \right\} \leq f_{k+1|k+1}^{\omega}(\mathbf{x}) \quad (9.36)$$

- 能够找到某些航迹状态  $\mathbf{x}_0$ , 有式 (9.37) 成立:

$$\max_{\mathbf{x}} \left\{ f_{k+1|k+1}^0(\mathbf{x}_0), f_{k+1|k+1}^1(\mathbf{x}_0) \right\} \leq f_{k+1|k+1}^{\omega}(\mathbf{x}_0) \quad (9.37)$$

式 (9.36) 表明, 与被融合的航迹密度相比, XM 融合密度  $f_{k+1|k+1}^{\omega}(\mathbf{x})$  设有减少信息量;

式 (9.37) 则表明  $f_{k+1|k+1}^{\omega}(\mathbf{x})$  在某些航迹状态  $\mathbf{x}_0$  下能够增加信息量。

为了获得 XM 融合密度  $f_{k+1|k+1}^{\omega}(\mathbf{x})$  的最优解, 优化选择被融合航迹统计密度的指数权重系数  $\omega$  起着关键作用。迄今为止有下述两种  $\omega$  的优化选择方法:

- (1) 一种理论上合理的  $\omega$  最优求解方法<sup>[3]</sup>:



$$\hat{\omega} = \arg \sup_{\omega} \sup_{\mathbf{x}} f_{k+1|k+1}^{\omega}(\mathbf{x}) \quad (9.38)$$

式(9.38)表示在式(9.34)确定的XM融合密度 $f_{k+1|k+1}^{\omega}(\mathbf{x})$ 达极大的状态 $\mathbf{x}$ 的上确界上,即在 $\mathbf{x}$ 的极大后验估计中,求取 $\omega$ 的上确界密度对应的指数权系数 $\hat{\omega}$ 。因此,式(9.38)表示 $\omega = \hat{\omega}$ 时, XM融合密度 $f_{k+1|k+1}^{\omega}(\mathbf{x})$ 给出的全局融合航迹 $(\hat{\mathbf{x}}_{k|k}, \hat{\mathbf{P}}_{k|k})$ 是极大后验(MAP)估计。

求取基于式(9.38)的 $\hat{\omega}$ 的一个近似方法与Uhlmann和Julier提出的方法相同<sup>[8-10]</sup>,即先计算XM融合密度 $f_{k+1|k+1}^{\omega}(\mathbf{x})$ 中的协方差 $\mathbf{P}_{k+1|k+1}^{\omega}$ ,再使其行列式最小或迹最小来确定 $\hat{\omega}$ ,如式(9.26)或式(9.27)所示。

(2) 使两个分布密度的Chernoff信息达极大的 $\hat{\omega}$ 是一个理论上更合理的 $\omega$ 最优解:

$$\hat{\omega} = \arg \inf_{\omega} \int_0^1 f_{k+1|k+1}^{\omega}(\mathbf{x})^{1-\omega} \cdot f_{k+1|k+1}^1(\mathbf{x})^{\omega} d\mathbf{x} \quad (9.39)$$

该式实际上是选择使得XM融合公式(9.34)分母中的归一化系数达极小的 $\hat{\omega}$ 值。其优点是可以降低被融合的加权分布密度 $f_{k+1|k+1}^0(\mathbf{x})^{1-\omega}$ 和 $f_{k+1|k+1}^1(\mathbf{x})^{\omega}$ 之间的重叠(相互覆盖)度,即增加二者的“距离”。这是由于式(9.39)通过使积分极小化确定 $\hat{\omega}$ ,反映了XM融合分布密度式(9.34)作为一个整体所包含的信息量达极大,而不仅仅是一个极大后验估计点所包含的信息量达极大。此外,可以证明,在Kullback—Leibler信息理论意义上, $f_{k+1|k+1}^{\hat{\omega}}(\mathbf{x})$ 与 $f_{k+1|k+1}^0(\mathbf{x})$ 、 $f_{k+1|k+1}^1(\mathbf{x})$ 的距离相等,因此其在理论上更合理。

对理论上的各种 $\omega$ 优选方法分析如下:

在目标跟踪过程中,如果无法从航迹分布 $f_{k|k}(\mathbf{x})$ 中提取精确的目标状态估计,则该航迹的统计没有多大应用价值,因为在目标跟踪中人们更关心的是目标航迹状态的估计精度,因此在一个目标活动范围内估计其整体分布 $f_{k|k}(\mathbf{x})$ 并无太大意义。例如,在实际应用中,大多数目标分布 $f_{k|k}(\mathbf{x})$ 的估计模式包含与目标无关杂波产生的次要模式和与一个目标关联的回波(SNR足够大)产生的主要模式。因此,采用一个整体分布 $f_{k|k}(\mathbf{x})$ 产生的目标航迹状态期望值 $\mathbf{x}_{k|k}$ 可能会产生不精确,甚至不稳定的估计。而采用式(9.7)获得的极大后验(MAP)估计会更适合于实际应用,因其能产生一个更精确和稳定的航迹状态估计。

如果从融合的概率密度 $f_{k+1|k+1}^{\omega}(\mathbf{x})$ 与两跟踪源局部航迹概率密度的偏差角度来讨论最优权值 $\hat{\omega}$ 的求取问题,则可将密度偏差作为理论上的信息距离(要注意与物理直觉距离概念不同),它存在一个字面上的无穷大的信息距离的概念(可理解为信息发散或无穷大散度)。最常见的Csiszár偏差(散度)族为<sup>[18,19]</sup>

$$K_C(f_{k+1|k+1}^1; f_{k+1|k+1}^0) = \int f_{k+1|k+1}^0(\mathbf{x}) \cdot c\left(\frac{f_{k+1|k+1}^1(\mathbf{x})}{f_{k+1|k+1}^0(\mathbf{x})}\right) d\mathbf{x} \quad (9.40)$$

式(9.40)可推广到多目标情况<sup>[20]</sup>,其中 $c(\mathbf{x})$ 是一个非负凸函数。当选择凸核 $c(\mathbf{x})$ 为

$c_{\omega}(\mathbf{x}) = (1-\omega)\mathbf{x} + \omega - \mathbf{x}^{\omega}$  时,

$$\begin{aligned} c_{\omega} \left( \frac{\frac{1}{f_{k+1|k+1}}(\mathbf{x})}{\frac{0}{f_{k+1|k+1}}(\mathbf{x})} \right) &= (1-\omega) \frac{\frac{1}{f_{k+1|k+1}}(\mathbf{x})}{\frac{0}{f_{k+1|k+1}}(\mathbf{x})} + \omega - \left( \frac{\frac{1}{f_{k+1|k+1}}(\mathbf{x})}{\frac{0}{f_{k+1|k+1}}(\mathbf{x})} \right)^{\omega} \\ &= \frac{\left[ (1-\omega) \frac{1}{f_{k+1|k+1}}(\mathbf{x}) + \omega \frac{0}{f_{k+1|k+1}}(\mathbf{x}) - \frac{1}{f_{k+1|k+1}}(\mathbf{x})^{\omega} \frac{0}{f_{k+1|k+1}}(\mathbf{x})^{1-\omega} \right]}{\frac{0}{f_{k+1|k+1}}(\mathbf{x})} \end{aligned}$$

于是, 式 (9.40) 成为

$$\begin{aligned} K_{C_{\omega}} &= \int \frac{0}{f_{k+1|k+1}}(\mathbf{x}) \cdot c_{\omega} \left( \frac{\frac{1}{f_{k+1|k+1}}(\mathbf{x})}{\frac{0}{f_{k+1|k+1}}(\mathbf{x})} \right) d\mathbf{x} \\ &= \int \left[ (1-\omega) \frac{1}{f_{k+1|k+1}}(\mathbf{x}) + \omega \frac{0}{f_{k+1|k+1}}(\mathbf{x}) \right] d\mathbf{x} - \int \frac{1}{f_{k+1|k+1}}(\mathbf{x})^{\omega} \frac{0}{f_{k+1|k+1}}(\mathbf{x})^{1-\omega} d\mathbf{x} \\ &= \int \frac{0}{f_{k+1|k+1}}(\mathbf{x}) d\mathbf{x} - \int \frac{1}{f_{k+1|k+1}}(\mathbf{x})^{\omega} \frac{0}{f_{k+1|k+1}}(\mathbf{x})^{1-\omega} d\mathbf{x} \\ &= 1 - \int \frac{1}{f_{k+1|k+1}}(\mathbf{x})^{\omega} \frac{0}{f_{k+1|k+1}}(\mathbf{x})^{1-\omega} d\mathbf{x} \end{aligned}$$

注意 Chernoff 信息的定义式 (9.35), 可知 Chernoff 信息也可用这里的  $K_{C_{\omega}}$  表示:

$$K_{C_{\omega}} \left( \frac{1}{f_{k+1|k+1}}; \frac{0}{f_{k+1|k+1}} \right) = 1 - \int \frac{1}{f_{k+1|k+1}}(\mathbf{x})^{\omega} \frac{0}{f_{k+1|k+1}}(\mathbf{x})^{1-\omega} d\mathbf{x} \quad (9.41)$$

由此可见, Chernoff 信息只是基于两概率分布密度偏差定义的信息距离领域中的一种度量尺度。

此外还有许多概率分布的距离度量尺度, 如 wasserstein 距离等。这样一来, 采用式 (9.39) 确定的 XM 融合的最优指数权值  $\hat{\omega}$  又涉及采用什么信息距离及其物理含义等问题。从某种意义上说, 不同的信息距离可能面向不同的物理问题, 因此无法选择或者说不存在最优的信息距离尺度。

由以上分析可以看出, 采用式 (9.38) 确定 XM 融合最优指数权值  $\hat{\omega}$  是目前实际应用中可能的选择方案, 使用该指数权值  $\hat{\omega}$  的融合公式 (9.34) 能够产生最优 XM 融合分布密度  $\frac{\hat{\omega}}{f_{k+1|k+1}}(\mathbf{x})$ , 并能够提取出最精确和最稳定的目标航迹状态估计。对于每一给出的权值  $\omega$ , XM 融合分布  $\frac{\omega}{f_{k+1|k+1}}(\mathbf{x})$  通常应具有下述性质:

- 它是两个局部航迹概率分布密度的融合概率分布密度;
- 该融合航迹的极大后验 (MAP) 估计是  $\mathbf{x}_{k+1|k+1}^{\omega} = \arg \sup_{\mathbf{x}} \frac{\omega}{f_{k+1|k+1}}(\mathbf{x})$ ;
- $\sup_{\mathbf{x}} \frac{\omega}{f_{k+1|k+1}}(\mathbf{x})$  的值越大, MAP 估计  $\mathbf{x}_{k+1|k+1}^{\omega}$  误差越小, 即目标航迹定位越准确;
- 所选择的最优指数权值  $\hat{\omega}$  应对应于 MAP 估计中的最佳定位的  $\omega$  值。

在本章后续部分将 XM 融合向多目标推广中, 这 4 个性质非常重要。在多目标环境中, 甚至无法定义协方差或航迹概念。虽然可以定义两个概率分布密度的 Chernoff 信息和 Csiszár 偏差的度量基准, 但与单目标情况相比, 它们的物理意义并不明确。在许多实际的多目标跟踪问题中, 难点在于式 (9.38) 的可计算性。因此, 在选择信息理论或其他优化

方法确定最优指数权值  $\hat{\omega}$  时, 计算上的可行性是最优先考虑的因素。

## 9.3 基于有限集统计学的多目标滤波方法

本节主要介绍基于有限集统计学(Finite—Set Statistics, FISST)的多目标滤波方法<sup>[7,21,22]</sup>, 目的是为后面几节所描述的基于 FISST 的多目标分布式融合方法及其计算实现提供所需知识。

### 9.3.1 多传感器多目标递推贝叶斯滤波

#### 1. 基本假设

采用多传感器多目标递推贝叶斯滤波实现多目标航迹—航迹融合 T<sup>2</sup>F(见文献[7]第 14 章), 其前提假设及其与单目标 T<sup>2</sup>F 问题的重要差别如下:

(1) 状态变量  $X$  是多目标中所含有的各单一目标状态的集合, 其形式为

$$X = \begin{cases} \emptyset & \text{没有发现目标} \\ \{\mathbf{x}_1\} & \text{发现状态为}\mathbf{x}_1\text{的一个目标} \\ \{\mathbf{x}_1, \mathbf{x}_2\} & \text{发现状态分别为}\mathbf{x}_1, \mathbf{x}_2\text{的两个目标} \\ \dots\dots & \end{cases} \quad (9.42)$$

(2)  $t_k$  时刻的测量和累积测量。

设  $Z_i$  由  $t_i$  或接近  $t_i$  时刻的所有有效传感器采集的测量值组成, 表示为

$$Z_i = \begin{cases} \emptyset & \text{没有发现目标} \\ \{\mathbf{z}_1\} & \text{采集到一个测量}\mathbf{z}_1 \\ \{\mathbf{z}_1, \mathbf{z}_2\} & \text{采集到两个测量}\mathbf{z}_1, \mathbf{z}_2 \\ \dots\dots & \end{cases} \quad (9.43)$$

$Z^{(k)}: Z_1, Z_2, \dots, Z_k$  为  $t_1, t_2, \dots, t_k$  时刻采集到的多传感器多目标有序测量集合。

(3) 多目标情况的目标数目变量  $n$  的后验概率定义为“基数分布”(cardinality distribution)形式:

$$p_{k+1|k+1}(n|Z^{(k+1)}) = \int_{|X|=n} f_{k+1|k+1}(X|Z^{(k+1)})\delta X \quad (9.44)$$

式中,  $\int \cdot \delta X$  是下一小节所定义的多目标的“集合积分”。

#### 2. 运动方程和测量方程

多目标运动方程(又称为状态转移方程)和测量方程是:

$$X_{k+1|k} = S_k(X) \cup B_k \quad (9.45)$$

$$Z_{k+1} = T_{k+1}(X) \cup C_{k+1} \quad (9.46)$$

其中,  $S_k(X)$  是从  $t_k$  时刻到  $t_{k+1}$  时刻持续存留的目标随机有限子集(Random Finite Subset, RFS);  $B_k$  是  $t_k$  时刻到  $t_{k+1}$  时刻新出现( $t_k$  时刻不存在,  $t_{k+1}$  时刻出现)目标的随机有限

子集； $T_{k+1}(X)$  是  $t_{k+1}$  时刻来源于目标的测量随机有限子集； $C_{k+1}$  是  $t_{k+1}$  时刻来源于杂波的测量随机有限子集。

基于模型 (9.45) 和 (9.46) 采用 9.3.2 节的多目标计算方法，可以构造一个多目标马尔可夫航迹状态转移概率密度和一个多目标条件似然函数（见文献[7]第 12、13 章）：

$$f_{k+1|k}(X|X'), f_{k+1}(Z_{k+1}|X) \quad (9.47)$$

然后，基于式 (9.45) ~ 式 (9.47) 模型的系统特征，在任一给定时刻  $t_k$  将假设的目标动态变化优势和不足与已知的传感器探测优势和不足以信息互补的形式系统地整合到一起，获取多目标状态（包括目标数量）的后验分布密度  $f_{k|k}(X|Z^{(k)})$ 。

### 3. 多目标贝叶斯滤波

在基于多目标状态转移方程 (9.45) 和多目标测量方程 (9.46) 确定多目标马尔可夫状态转移概率密度和  $t_{k+1}$  时刻测量  $Z_{k+1}$  的条件似然函数之后，可以得到多目标贝叶斯递推滤波公式，由下述预测（时间更新）方程和更新（测量更新）方程组成：

$$f_{k+1|k}(X|Z^{(k)}) = \int f_{k+1|k}(X|X') f_{k|k}(X|Z^{(k)}) \delta X' \quad (9.48)$$

$$f_{k+1|k+1}(X|Z^{(k+1)}) = \frac{f_{k+1}(Z_{k+1}|X) f_{k+1|k}(X|Z^{(k)})}{f_{k+1}(Z_{k+1}|Z^{(k)})} \quad (9.49)$$

式 (9.49) 中，归一化因子为

$$f_{k+1}(Z_{k+1}|Z^{(k)}) = \int f_{k+1}(Z_{k+1}|X) f_{k+1|k}(X|Z^{(k)}) \delta X \quad (9.50)$$

与单目标情况类似，以下对所有  $k$ ，简写为

$$\begin{aligned} f_{k|k}(X) &= f_{k|k}(X|Z^{(k)}) \\ f_{k+1|k}(X) &= f_{k+1|k}(X|Z^{(k)}) \end{aligned} \quad (9.51)$$

与图 9.1 单目标递推滤波流程类似，多目标贝叶斯滤波随多目标测量的逐次到来不断生成和传播多目标后验分布密度，如图 9.5 所示。

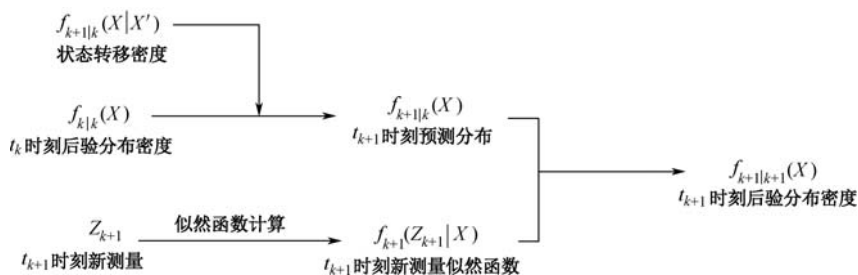


图 9.5 多目标贝叶斯后验密度递推流程

值得指出的是，在获得了多目标贝叶斯后验估计  $f_{k+1|k+1}(X)$  之后，即可从中同时提取出所需要的目标数量和各单一目标的位置、速度以及属性信息（见文献[7]14.5 节）。例如，一个联合多目标（joint multitarget）估计器（JoM）的定义如下：

$$X_{k+1|k+1}^{\text{JoM}} = \arg \sup_X f_{k+1|k+1}(X|Z^{(k+1)}) \cdot \frac{c^{|X|}}{|X|!} \quad (9.52)$$

这里提取出的  $X_{k+1|k+1}^{\text{JoM}}$  包含了所需要的多目标各类信息。其中  $c$  是一个固定常数，通常与多目标状态  $X$  的测量单位（各目标测量的分辨率）相同。一般来说， $c$  应大致等于估计的目标状态精度，只要对所有  $X$  满足不等式<sup>[7]</sup>：

$$f_{k+1|k+1}(X) \cdot c^{\hat{n}} \leq 1 \quad (9.53)$$

式中， $\hat{n}$  是从式 (9.44) 表示的基数分布获得的目标数量的极大后验 (MAP) 估计。

### 9.3.2 多目标随机分布的计算方法

#### 1. 多目标随机过程的积分和微分运算

多目标随机过程的积分—微分运算是本章提出的基于有限集统计学的多目标 T<sup>2</sup>F 算法所需要的核心。泛函的导数与集合的导数（见文献[7]第 11 章）是构造实用的多目标马尔可夫状态转移概率密度和多目标似然函数的关键，也是构造多目标贝叶斯滤波的理论近似，如概率假设密度 (Probability Hypothesis Density, PHD) 滤波和基数 PHD (Cardinalized PHD, CPHD) 滤波的关键。

随机集合的积分用来说明目标数量和各目标状态的整体随机可变性。设  $f_{k|k}(X)$  是一个多目标概率分布密度，则其对含有多目标状态和数量的随机集合  $X$  的积分定义为如下形式：

$$\int f(X) \delta X = f(\emptyset) + \sum_{n=1}^{\infty} \frac{1}{n!} \int f_{k|k} \{x_1, \dots, x_n\} dx_1 \cdots dx_n \quad (9.54)$$

令  $F[h]$  为任一泛函，是函数自变量  $h(x)$ ,  $x \in X = \{x_1, \dots, x_n\}$  的一个标量函数，则泛函  $F$  对满足  $|X| = n \geq 0$  的任何有限随机集合  $X = \{x_1, \dots, x_n\}$  的导数可以表示为（注意此时函数自变量为  $h(x)$ ）

$$\frac{\delta F}{\delta X}[h] = \frac{\delta}{\delta x_1} \cdots \frac{\delta}{\delta x_n} F[h] \quad (9.55)$$

其中，偏微分为

$$\frac{\delta}{\delta x} F[h] = \lim_{\varepsilon \searrow 0} \frac{F[h + \varepsilon \delta_x] - F[h]}{\varepsilon} \quad (9.56)$$

这里， $\delta_x(x')$  表示浓缩于  $x$  点的狄拉克函数。

泛函的导数与积分是互逆运算，即对任何函数自变量  $h(x)$ ，可得：

$$F[h] = \int h^X \cdot \frac{\delta F}{\delta X}[0] \delta X$$

如果视集合  $X$  为离散的自变量函数，即  $X = h(x) = \{x_1, \dots, x_n\}$ ，视  $f(X)$  为关于  $X$  的泛函，则由式 (9.54) 定义的  $f(X)$  积分与其导数也是互逆运算，即

$$\left[ \frac{\delta}{\delta X} \int h^X \cdot f(X) \delta X \right]_{h=0} = f(X)$$

这里，

$$h^X = \begin{cases} 1 & X = \emptyset \\ \prod_{x \in X} h(x) & \text{其他} \end{cases} \quad (9.57)$$

## 2. 多目标概率分布假设

在本章后面几节的基于多目标航迹概率密度的  $T^2F$  中, 会频繁使用两个特定分布的多目标随机过程。设  $f(X)$  是一个多目标概率分布, 其服从以下两个随机分布。

(1) 泊松过程 (Poisson 随机有限子集 RFS)。

$$f(X) = e^{-N} D^X \quad (9.58)$$

式中,  $N = \int_{x \in X} D(x) dx$ ,  $D(x)$  是概率假设密度 (PHD), 或称其为该过程的强度函数,  $D(x)$

并不是某一目标状态  $x$  的分布密度, 而是多目标随机过程中在某单一目标状态  $x$  处的航迹分布密度, 因此其在  $x \in X$  中的积分  $N$  是该多目标过程  $X$  中期望的总目标数量。 $D(x)$  的准确定义见 9.3.3 节。 $D^X$  的定义与  $h^X$  的定义式 (9.57) 类似, 即

$$D^X = \begin{cases} 1 & X = \emptyset \\ \prod_{x \in X} D(x) & \text{其他} \end{cases} \quad (9.59)$$

(2) 独立同分布聚类 (Independent Identically Distributed Cluster, IIDC) 随机有限子集 (RFS)。

$$f(X) = |X|! p(|X|) s^X \quad (9.60)$$

其中,  $s(x)$  是多目标随机过程  $X$  在单一目标状态  $x$  处 (附近) 的空间密度,  $s^X$  的定义与  $D^X$  类似:

$$s^X = \begin{cases} 1 & X = \emptyset \\ \prod_{x \in X} s(x) & \text{其他} \end{cases} \quad (9.61)$$

$p(n)$  是该多目标随机过程的基数分布密度, 定义见式 (9.44)。

可以证明, 式 (9.58) 定义了一个多目标概率分布密度。实际上, 注意式 (9.54) 和式 (9.59), 可得该概率分布的完备性:

$$\begin{aligned} \int f(X) \delta X &= e^{-N} D^\emptyset + e^{-N} \sum_{n=1}^{\infty} \frac{1}{n!} \int D(x_1) \cdots D(x_n) dx_1 \cdots dx_n \\ &= e^{-N} + e^{-N} \sum_{n=1}^{\infty} \frac{1}{n!} N^n = e^{-N} e^N = 1 \end{aligned}$$

同样注意式 (9.54) 和式 (9.61), 可以证明式 (9.60) 也定义了一个多目标概率分布密度, 其具有完备性:

$$\begin{aligned} \int f(X) \delta X &= 0! p(0) s^\emptyset + \sum_{n=1}^{\infty} \frac{n! p(n)}{n!} \int s(x_1) \cdots s(x_n) dx_1 \cdots dx_n \\ &= p(0) + \sum_{n=1}^{\infty} p(n) = 1 \end{aligned}$$

同样可以证明, 式 (9.58) 所示的  $f(X)$  的泊松过程是式 (9.60) 所示的 IIDC 过程在  $p(n) = e^{-N} N^n / n!$  时的一个特例。因此, 采用 IIDC 作为多目标概率分布更具有通用性。

### 9.3.3 概率假设密度 (PHD) 滤波

单目标卡尔曼滤波 (多目标环境中通过关联处理产生源于单一目标的测量集合, 再进行单目标卡尔曼滤波) 随着新测量的到来, 不断通过交替使用预测过程  $\hat{\mathbf{x}}_{k|k} \rightarrow \hat{\mathbf{x}}_{k+1|k}$  和更新过程  $\hat{\mathbf{x}}_{k+1|k} \rightarrow \hat{\mathbf{x}}_{k+1|k+1}$ , 递推产生目标状态的后验估计 (又称为一阶矩)。当采取不变增益时, 如  $\alpha-\beta$  滤波, 则该递推运算更加简便, 并能够产生适宜的近似优化滤波结果。我们知道, 无论是单目标还是多目标 T<sup>2</sup>F, 基于概率分布密度的预测—更新过程对于理论分析很有用, 但若无法从更新密度中提取出各单一目标航迹估计 ( $\mathbf{x}_{k+1|k+1}, \mathbf{P}_{k+1|k+1}$ ), 则并无实际应用价值。这也正是直接面向单一目标状态估计的卡尔曼滤波或其近似方法的实用优势。

面向多目标 (基于有限统计集) 的 PHD 滤波效仿卡尔曼滤波的基本思想, 但在基于有限统计集的更加抽象的多目标统计层面上 (见文献[7]第 16 章和文献[23]), 以多目标一阶矩, 而不是多目标后验概率密度  $f_{k|k}(\mathbf{X} | \mathbf{Z}^{(k)})$  为统计变量。多目标一阶矩又称为概率假设密度 PHD, 其定义为如下后验期望值:

$$D_{k|k}(\mathbf{x}) = D_{k|k}(\mathbf{x} | \mathbf{Z}^{(k)}) = \int f_{k|k}(\mathbf{X} \cup \{\mathbf{x}\} | \mathbf{Z}^{(k)}) \delta \mathbf{X} \quad (9.62)$$

由式 (9.62) 可见,  $D_{k|k}(\mathbf{x})$  并不是单一目标状态  $\mathbf{x}$  自身的可能分布概率密度, 其在直观上表示在多目标环境中某单一目标状态  $\mathbf{x}$  处 (及其附近) 的目标航迹数量, 其峰值近似位于最可能的目标航迹定位点附近。这样一来, 多目标环境中的期望的总目标数可以定义为

$$N_{k|k} = \int D_{k|k}(\mathbf{x}) d\mathbf{x} \quad (9.63)$$

显然,  $N_{k|k}$  通常不为 1, 这充分说明  $D_{k|k}(\mathbf{x})$  绝非单一目标状态  $\mathbf{x}$  的概率密度。估计目标数量  $\hat{n}$  及预测这些目标航迹位置  $\hat{\mathbf{x}}_1, \hat{\mathbf{x}}_2, \dots, \hat{\mathbf{x}}_{\hat{n}}$  的一种方法就是取与  $N_{k+1|k}$  最接近的整数作为  $\hat{n}$ , 然后确定  $D_{k|k}(\mathbf{x})$  的  $\hat{n}$  个最高峰值位置作为各目标位置。

多目标 PHD (一阶矩) 滤波一步递推流程如图 9.6 所示。




图 9.6 多目标 PHD 滤波一步递推流程

图 9.6 中的 PHD 一步预测公式为

$$D_{k+1|k}(\mathbf{x}) = N_{k+1|k}^B s_{k+1|k}^B(\mathbf{x}) + \int p_S(\mathbf{x}') f_{k+1|k}(\mathbf{x} | \mathbf{x}') D_{k|k}(\mathbf{x}') d\mathbf{x}' \quad (9.64)$$

PHD 一步更新公式为

$$\frac{D_{k+1|k+1}(\mathbf{x})}{D_{k+1|k}(\mathbf{x})} = 1 - p_D(\mathbf{x}) + \sum_{z \in Z_{k+1}} \frac{p_D(\mathbf{x}) L_z(\mathbf{x})}{\lambda_{k+1} c_{k+1}(\mathbf{z}) + \tau_{k+1}(\mathbf{z})} \quad (9.65)$$

对式 (9.64) 说明如下:

- $N_{k+1|k}^B$  为  $[t_k, t_{k+1}]$  中预测的所有新生目标期望数,  $s_{k+1|k}^B(\mathbf{x})$  表示目标  $\mathbf{x}$  处新生目标的预测密度, 故二者之积表示  $t_{k+1}$  时刻在目标状态  $\mathbf{x}$  附近新生的目标航迹数。
- $p_S(\mathbf{x}') = p_{S, k+1|k}(\mathbf{x}')$  表示目标  $\mathbf{x}'$  在  $[t_k, t_{k+1}]$  中持续存在的概率,  $f_{k+1|k}(\mathbf{x}|\mathbf{x}')$  为单一目标状态  $\mathbf{x}$  的马尔可夫转移密度, 故式 (9.64) 右端积分项表示从  $t_k$  时刻所有存在的目标  $\mathbf{x}'$  转移到  $t_{k+1}$  时刻目标  $\mathbf{x}$  附近的预测航迹数。
- 式 (9.64) 表示  $t_{k+1}$  时刻预测的单一目标状态  $\mathbf{x}$  附近出现的目标航迹数量。

对式 (9.65) 说明如下:

- $p_D(\mathbf{x}) = p_{D, k+1}(\mathbf{x})$  表示目标  $\mathbf{x}$  在  $t_{k+1}$  时刻产生一个测量的概率,  $L_z(\mathbf{x}) = f_{k+1}(\mathbf{z}|\mathbf{x})$  为  $t_{k+1}$  时刻目标  $\mathbf{x}$  测量的似然函数,  $p_D(\mathbf{x})L_z(\mathbf{x})$  表示来自目标  $\mathbf{x}$  的测量  $\mathbf{z}$  出现的概率。
- $\lambda_{k+1}$  表示杂波率,  $c_{k+1}(\mathbf{z})$  表示服从泊松过程的测量  $\mathbf{z}$  的空间分布, 于是  $\lambda_{k+1}c_{k+1}(\mathbf{z})$  表示  $t_{k+1}$  时刻测量  $\mathbf{z}$  为杂波的概率。
- $\tau_{k+1}(\mathbf{z})$  为测量  $\mathbf{z}$  来自目标的概率 (检测概率):

$$\tau_{k+1}(\mathbf{z}) = \int p_D(\mathbf{x})L_z(\mathbf{x})D_{k+1|k}(\mathbf{x})d\mathbf{x} \quad (9.66)$$

- 式 (9.65) 右端求和式中分母表示 (目标与杂波) 回波出现的概率。
- 式 (9.65) 右端求和项表示  $t_{k+1}$  时刻测量集合  $Z_{k+1}$  中所包含的来自目标  $\mathbf{x}$  的测量概率与所有回波 (含杂波和目标回波) 出现概率之比。
- $1 - p_D(\mathbf{x})$  为  $t_{k+1}$  时刻没有目标  $\mathbf{x}$  测量的概率, 于是, PHD 更新公式 (9.65) 右端给出了  $t_{k+1}$  时刻单一目标状态  $\mathbf{x}$  附近的航迹后验估计密度与预测密度之间的比例系数。

我们从期望目标数量的角度, 可以更直观地理解 PHD 滤波一步测量更新公式 (9.65)。为此, 将式 (9.65) 改写为

$$D_{k+1|k+1}(\mathbf{x}) = [1 - p_D(\mathbf{x})]D_{k+1|k}(\mathbf{x}) + \sum_{z \in Z_{k+1}} \frac{p_D(\mathbf{x})L_z(\mathbf{x})D_{k+1|k}(\mathbf{x})}{\lambda_{k+1}c_{k+1}(\mathbf{z}) + \tau_{k+1}(\mathbf{z})}$$

该式在多目标状态空间中对目标状态积分, 注意式 (9.66), 可得  $t_{k+1}$  时刻目标总数量为

$$\begin{aligned} N_{k+1|k+1} &= \int D_{k+1|k+1}(\mathbf{x})d\mathbf{x} = \int [1 - p_D(\mathbf{x})]D_{k+1|k}(\mathbf{x})d\mathbf{x} + \sum_{z \in Z_{k+1}} \frac{\tau_{k+1}(\mathbf{z})}{\lambda_{k+1}c_{k+1}(\mathbf{z}) + \tau_{k+1}(\mathbf{z})} \\ &= \overset{ND}{N}_{k+1|k+1} + \sum_{z \in Z_{k+1}} \overset{D}{N}_{k+1|k+1}(\mathbf{z}) \end{aligned} \quad (9.67)$$

这里,

$$\overset{ND}{N}_{k+1|k+1} = \int [1 - p_D(\mathbf{x})]D_{k+1|k}(\mathbf{x})d\mathbf{x} \quad (9.68)$$

$$\overset{D}{N}_{k+1|k+1}(\mathbf{z}) = \frac{\tau_{k+1}(\mathbf{z})}{\lambda_{k+1}c_{k+1}(\mathbf{z}) + \tau_{k+1}(\mathbf{z})} \leq 1 \quad (9.69)$$

式 (9.68) 所示的非检测项  $\overset{ND}{N}_{k+1|k+1}$  表示对  $t_{k+1}$  时刻未检测到的目标数的预测结果; 而式



(9.69) 所示的检测率  $\bar{N}_{k+1|k+1}^D(\mathbf{z})$  则表示测量  $\mathbf{z}$  来自目标的概率比例, 故检测项  $\sum_{\mathbf{z} \in Z_{k+1}} \bar{N}_{k+1|k+1}^D(\mathbf{z})$  表示  $t_{k+1}$  时刻的测量集合  $Z_{k+1}$  中所含有的检测到的目标数量。如果  $\bar{N}_{k+1|k+1}^D(\mathbf{z}) > 0.5$ , (即  $\lambda_{k+1} c_{k+1}(\mathbf{z}) < \tau_{k+1}(\mathbf{z})$ ), 则测量  $\mathbf{z}$  像是目标; 若  $\bar{N}_{k+1|k+1}^D(\mathbf{z}) < 0.5$ , 则测量  $\mathbf{z}$  更像杂波。

导出 PHD 滤波的更新公式 (9.65) 需要假设该预期的目标过程近似为泊松分布, 这使得式 (9.65) 右端求和式中分子  $p_D(\mathbf{x})L_z(\mathbf{x})$  (即测量  $\mathbf{z}$  来自单一目标  $\mathbf{x}$  的概率) 的计算得以实现。因此, PHD 滤波不需要显式的测量—航迹关联过程。更新公式 (9.65) 的计算复杂度为  $O(mn)$ , 这里  $m$  是  $Z_{k+1}$  所含测量数,  $n$  为  $t_{k+1}$  时刻目标数。人们通常倾向于在某个时间窗口内取  $N_{k|k}$  均值以产生目标数量的瞬时低精度估计 (具有较高方差)。

PHD 滤波可以采用两种方法实现: 序贯蒙特卡罗 (Sequential Monte Carlo, SMC, 又名粒子系统) 近似或高斯混合近似。前一种方法称为“粒子 PHD 滤波”, 后一种方法称为“高斯混合 PHD 滤波” (见文献[7]第 16 章和文献[45-47])。

### 9.3.4 基数概率假设密度 (CPHD) 滤波

上一节所描述的 PHD 滤波采用泊松分布作为多目标概率密度模型 (即杂波模型), 因此, 每一步递推过程仅产生和传递每个单一目标附近的目标航迹数量  $D_{k|k}(\mathbf{x}|Z^{(k)})$  即一阶矩, 然后基于对式 (9.63) 所描述的近似方法确定目标数量估计  $\hat{n}$  及相应的  $\hat{n}$  个目标状态。也可以基于式 (9.64) 和式 (9.65), 在确定了从  $t_k$  时刻传递到  $t_{k+1}$  时刻的  $D_{k+1|k+1}(\mathbf{x}|Z^{(k+1)})$  之后, 采用式 (9.67) 获得目标数量的期望值  $\hat{n}$ 。

本节描述的基数概率假设密度滤波 (CPHD) 滤波是 PHD 滤波向通用化的扩展, 见文献[7]第 16 章和文献[23]。与 PHD 滤波采用泊松杂波 (虚警) 模型相比, 多目标 CPHD 滤波采用更通用的独立同分布聚类 (IIDC) 虚警模型, 其每一步递推过程产生和传递两个统计分布密度: 多目标航迹状态的空间后验分布密度  $s_{k|k}(\mathbf{x}) = s_{k|k}(\mathbf{x}|Z^{(k)})$  和目标数量 (基数) 的后验分布密度  $p_{k|k}(n) = p_{k|k}(n|Z^{(k)})$ 。

多目标 CPHD 滤波一步递推流程如图 9.7 所示。

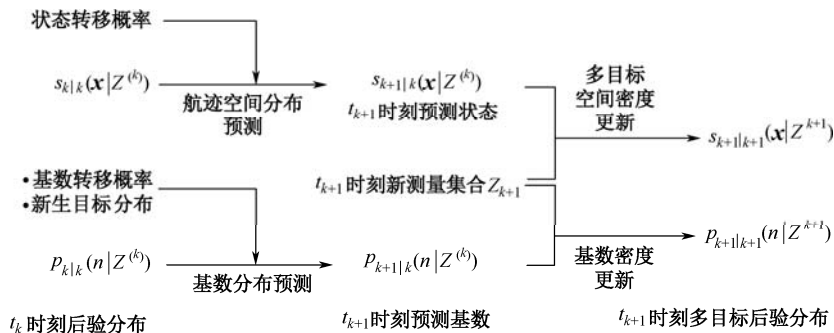


图 9.7 多目标 CPHD 滤波一步递推流程

我们注意到  $N_{k|k} = \sum_{n \geq 0} n p_{k|k}(n | Z^{(k)})$  是目标数量的期望值, 而  $s_{k|k}(\mathbf{x})$  表示目标航迹的空间分布, 故  $N_{k|k} \cdot s_{k|k}(\mathbf{x})$  表示状态  $\mathbf{x}$  处的目标航迹数量, 即 PHD 滤波的一阶矩  $D_{k|k}(\mathbf{x} | Z^{(k)})$ , 于是

$$s_{k|k}(\mathbf{x}) = D_{k|k}(\mathbf{x} | Z^{(k)}) / N_{k|k} \quad (9.70)$$

(1) CPHD 滤波的一步预测 (时间更新) 方程。

基于式 (9.70), 空间分布预测  $s_{k+1|k}(\mathbf{x})$  仍采用与式 (9.64) 相同的一阶矩的预测形式  $D_{k+1|k}(\mathbf{x})$ :

$$D_{k+1|k}(\mathbf{x}) = b_{k+1|k}(\mathbf{x}) + \int p_S(\mathbf{x}') f_{k+1|k}(\mathbf{x} | \mathbf{x}') D_{k|k}(\mathbf{x}') d\mathbf{x}' \quad (9.71)$$

其中,  $b_{k+1|k}(\mathbf{x}) = N_{k+1|k}^B s_{k+1|k}^B(\mathbf{x})$  表示  $t_{k+1}$  时刻单一目标状态  $\mathbf{x}$  处的再生航迹数量, 积分项表示从  $t_k$  时刻到  $t_{k+1}$  时刻持续存在目标  $\mathbf{x}'$  演变为  $t_{k+1}$  时刻目标  $\mathbf{x}$  的航迹数量。

基数分布密度预测公式为

$$p_{k+1|k}(n) = \sum_{n' \geq 0} p_{k+1|k}(n | n') p_{k|k}(n') \quad (9.72)$$

其中,  $p_{k+1|k}(n | n')$  是  $t_k$  时刻目标数  $n'$  向  $t_{k+1}$  时刻目标数  $n$  的转移概率:

$$p_{k+1|k}(n | n') = \sum_{j=0}^n p_{k+1|k}^B(n-j) \cdot C_{n',j} \cdot \psi_k^j (1-\psi_k)^{n'-j} \quad (9.73)$$

这里,  $p_{k+1|k}^B(n-j)$  是  $[t_k, t_{k+1}]$  时段新出现  $n-j$  个目标的预测分布密度:

$$\psi_k = \int p_S(\mathbf{x}) s_{k+1|k}(\mathbf{x}) d\mathbf{x} \quad (9.74)$$

$C_{n',j}$  是  $[t_k, t_{k+1}]$  时段持续存在的目标预测概率:

$$C_{n',j} = \begin{cases} \frac{n'!}{j!(n'-j)!} & 0 \leq j \leq n' \\ 0 & \text{其他} \end{cases} \quad (9.75)$$

目标数量预测公式为

$$N_{k+1|k} = N_{k+1|k}^B + \int p_S(\mathbf{x}') D_{k|k}(\mathbf{x}') d\mathbf{x}' \quad (9.76)$$

其中,  $N_{k+1|k}^B$  是预测的  $[t_k, t_{k+1}]$  时段新出现的目标数量:

$$N_{k+1|k}^B = \int b_{k+1|k}(\mathbf{x}) d\mathbf{x} \quad (9.77)$$

这里,  $b_{k+1|k}(\mathbf{x})$  是新出现目标的密度。式 (9.76) 右端积分项是  $[t_k, t_{k+1}]$  中持续存在的目标数量。

(2) CPHD 滤波更新方程。

设在  $t_{k+1}$  时刻获得的多目标测量集合  $Z_{k+1} = \{z_1, \dots, z_m\}$ ,  $|Z_{k+1}| = m$ , 则 CPHD 滤波的更新方程表示如下。

空间分布更新方程:

$$\frac{D_{k+1|k+1}(\mathbf{x})}{S_{k+1|k}(\mathbf{x})} = [1 - p_D(\mathbf{x})] E_{k+1}^{ND} + \sum_{z \in Z_{k+1}} p_D(\mathbf{x}) L_z(\mathbf{x}) E_{k+1}^D(z) \quad (9.78)$$

基数分布更新方程：

$$\frac{p_{k+1|k+1}(n)}{p_{k+1|k}(n)} = \frac{\sum_{j=0}^{\min\{m,n\}} (m-j)! \cdot p_{k+1}^{\kappa}(m-j) \cdot P_{n,j} \cdot \phi_k^{n-j} \sigma_j(Z_{k+1})}{\sum_{l=0}^m (m-l)! \cdot p_{k+1}^{\kappa}(m-l) \cdot \sigma_l(Z_{k+1}) \cdot G_{k+1|k}^{(l)}(\phi_k)} \quad (9.79)$$

式 (9.78) 类似于式 (9.65) 的推导，其中，

$$E_{k+1}^{ND} = \frac{\sum_{j=0}^m (m-j)! \cdot p_{k+1}^{\kappa}(m-j) \cdot \sigma_j(Z_{k+1}) \cdot G_{k+1|k}^{(j+1)}(\phi_k)}{\sum_{l=0}^m (m-l)! \cdot p_{k+1}^{\kappa}(m-l) \cdot \sigma_l(Z_{k+1}) \cdot G_{k+1|k}^{(l)}(\phi_k)} \quad (9.80)$$

表示  $t_{k+1}$  时刻未检测出来的目标数量的预测结果， $1-p_D(\mathbf{x})$  为未产生目标  $\mathbf{x}$  的测量概率， $L_z(\mathbf{x}) = f_{k+1}(\mathbf{z}|\mathbf{x})$  为基于目标  $\mathbf{x}$  的测量  $\mathbf{z}$  的似然函数。式 (9.78) 中，

$$E_{k+1}^D(\mathbf{z}) = \frac{1}{c_{k+1}(\mathbf{z})} \frac{\sum_{j=0}^{m-1} (m-j-1)! \cdot p_{k+1}^{\kappa}(m-j-1) \cdot \sigma_j(Z_{k+1} - \{\mathbf{z}_j\}) \cdot G_{k+1|k}^{(j+1)}(\phi_k)}{\sum_{l=0}^m (m-l)! \cdot p_{k+1}^{\kappa}(m-l) \cdot \sigma_l(Z_{k+1}) \cdot G_{k+1|k}^{(l)}(\phi_k)} \quad (9.81)$$

表示  $t_{k+1}$  时刻检测到的目标数量预测结果， $\kappa(\mathbf{z}) = \lambda_{k+1} \cdot \theta_c(\mathbf{z})$  表示测量  $\mathbf{z}$  的泊松分布密度 (强度)，故  $p_{k+1}^{\kappa}(m)$  表示基于分布密度叠加的测量数量分布密度。

在式 (9.79) ~ 式 (9.81) 中：

$$\sigma_j(Z_{k+1}) = \sigma_{m,j} \left( \frac{\tau_{k+1}(\mathbf{z}_1)}{c_{k+1}(\mathbf{z}_1)}, \dots, \frac{\tau_{k+1}(\mathbf{z}_m)}{c_{k+1}(\mathbf{z}_m)} \right) \quad (9.82)$$

为  $Z_{k+1}$  中所含  $m$  个测量的信杂比确定的标准偏差，其中

$$\tau_{k+1}(\mathbf{z}) = \int p_D(\mathbf{x}) L_z(\mathbf{x}) s_{k+1|k}(\mathbf{x}) d\mathbf{x} \quad (9.83)$$

为目标状态  $\mathbf{x}$  附近的测量 (目标信号) 数量；

$$\phi_k = \int [1 - p_D(\mathbf{x})] s_{k+1|k}(\mathbf{x}) d\mathbf{x} \quad (9.84)$$

表示  $t_{k+1}$  时刻所有未检测到目标的预测数；

$$G_{k+1|k}^{(j+1)}(\phi_k) = \sum_{n' \geq j+1} C_{n',j+1} \cdot p_{k+1|k}(n') \phi_k^{n'-j-1} \quad (9.85)$$

表示  $n' \geq j+1$  的所有目标数  $n'$  的组合产生的未检测目标数的二项分布；

$$G_{k+1|k}^{(l)}(\phi_k) = \sum_{n' \geq l} C_{n',l} \cdot p_{k+1|k}(n') \phi_k^{n'-l} \quad (9.86)$$

表示  $n' \geq l$  的所有目标数  $n'$  的组合产生的未检测目标数的二项分布，其中， $C_{n,i} = \frac{n!}{(n-i)!}$

是  $n$  中取  $i$  ( $\leq n$ ) 的组合系数。

CPHD 滤波的更新方程 (9.78) 和 (9.79) 需要的简化假设是：多目标空间分布近似为一个独立的同分布杂波过程。其计算强度级为  $O(m^3n)$ ，但是采用专用的数值计算方法可以降低为  $O(m^2n)$ 。

该 CPHD 滤波可以使用粒子近似和高斯混合近似实现,前者称为“粒子 CPHD 滤波”,后者称为“高斯混合 CPHD 滤波”。

### 9.3.5 基于随机集的滤波技术应用近况

随机集又被称为有限统计集,近年来基于随机集理论的滤波方法和应用有了一定进展。这里对近期主要的几项进展情况简要概述如下:

(1) 基于原始像素图的检测前跟踪 (Tracking Before Detect, TBD) 算法。在当前应用的基于遥感或探测像素图进行目标跟踪的方法中,大多数是对原始探测图像进行预处理,实现目标信号检测,如基于门限(阈值)的检测、目标边缘检测、目标特征点(奇异点)检测等,这些方法往往对每一帧原始图像进行检测,忽略了帧间目标状态的变化和状态统计积累,使得对低信杂比目标难以检测。TBD 技术将诸帧图像视为一个多阶段检测过程,文献[48]第3章介绍了当前正在研究并已部分应用的基于动态规划的 TBD、基于粒子滤波的 TBD 以及基于霍夫变换的 TBD 等技术。文献[24]提出的一种无需预处理的多目标检测与跟踪算法是对文献[7]第17章的“多贝努里滤波器”进行适当修改实现的<sup>[25]</sup>。

(2) 并行定位与标绘 (Simultaneous Localization And Mapping, SLAM)。当空中平台中的 GPS 和地图都无法使用时,该平台需要能够进行地标检测以创建航行地图,并确定本平台相对于该地图的位置。快速 SLAM 是一项用于并行同步定位与地图标绘的最新技术,采用测量—航迹关联,并组合启发式杂波抑制和地标标绘开始/停止技术。文献[26,27]构建了一个基于 PHD 滤波的 SLAM 滤波器,其对平台自身航迹估计和地标检测定位的精度比快速 SLAM 更高。文献[28]给出了一个基于一个杂波处理公式的更快、更精确的 SLAM—PHD 滤波器。

(3) “背景无关” (Background Agnostic, BAG) CPHD 滤波器。“经典” CPHD 滤波依赖杂波过程的先验模型:杂波率  $\lambda_{k+1}$ 、泊松过程的杂波空间分布  $c_{k+1}(\mathbf{z})$ 、测量集合  $Z_{k+1}$  所含杂波数  $m$  的分布  $p_{k+1}^K(m)$  以及依赖于状态的检测概率的一个先验模型  $p_D(\mathbf{x})$ 。2009 年, Ronald Mahler 开始研究不需要先验杂波模型的 PHD 与 CPHD 组合的滤波方法,在平台飞行中能够通过测量直接估计确定杂波分布模型。在文献[29,30]中,杂波过程被假设为对泊松过程的一个有限次叠加,每个泊松杂波过程的强度为  $\kappa = \lambda \cdot \theta_c(\mathbf{z})$ ,其中杂波率  $0 \leq \lambda \leq 1$ ,杂波  $\mathbf{z}$  的空间分布  $\theta_c(\mathbf{z})$  带有参数  $c$ 。然而,上述组合的 PHD/CPHD 滤波在计算上过于复杂,无法实际应用。随后的文献[31]提出一种计算上可行的 CPHD 滤波方法,其中假设杂波过程为贝努里杂波过程的无限次叠加,并且每个贝努里杂波过程都有相应的强度  $\kappa = \lambda \cdot \theta_c(\mathbf{z})$ ,杂波率  $0 \leq \lambda \leq 1$ 。文献[32]则进一步表明,当杂波过程和检测概率  $p_D(\mathbf{x})$  均未知时应如何扩展上述滤波方法;该扩展滤波方法已在某一特定背景下实现,在仿真环境中能够合理地运行<sup>[33,34]</sup>。

(4) “背景无关”多贝努里滤波器。目前 Vo Vo Hoseinnezhad 和 Mahler 采用背景无关多贝努里滤波的粒子滤波器实现了将上述各种背景无关 CPHD 滤波方法推广到非线性情况<sup>[35-37]</sup>。

(5) 多传感器 CPHD/PHD 滤波方法。9.3.3 节 PHD 滤波所描述的基于  $t_{k+1}$  时刻测量集合  $Z_{k+1}$  的多目标后验密度函数的一阶矩  $D_{k+1|k+1}(\mathbf{x})$  的更新步骤, 以及 9.3.4 节 CPHD 滤波中多目标空间分布  $s_{k+1|k+1}(\mathbf{x})$  和基数分布  $p_{k+1|k+1}(\mathbf{x})$  的更新步骤, 在本质上都是单传感器(单源)测量的情况。在实际应用的多传感器情况下, 多采用“迭代修正”的近似方法, 一次迭代中, 每个传感器依次使用一次更新方程, 因为改变各传感器的排序会产生不同的修正结果, 并且对 PHD 滤波来说, 当各传感器的检测概率相差较大时, 该迭代修正方法会导致性能降低(对 CPHD 滤波则不明显)<sup>[38]</sup>。文献[39]介绍了一种新的近似方法, 该方法是一种规范化、不需要改变传感器排序且易于计算的多传感器 PHD 和 CPHD 滤波方法。文献[40]表明, 这种新的近似方法比迭代修正近似方法更好, 并且对于 PHD 滤波来说, 它也是在理论上修正双传感器 PHD 滤波的一个较好的近似。

(6) 联合进行多传感器目标跟踪与传感器偏差(即测量误差)估计。目前的多目标检测与跟踪算法都假设所有传感器是已经空间配准的, 也就是说, 所有传感器的工作(探测)状态相对于某个公共坐标系都已精确地确定。事实上, 任何传感器的测量都会由于平移、旋转或其他形式的失配偏差而恶化。文献[41]提出了一种方法, 即利用所获得的足够的任意位置目标测量, 在对目标进行检测与跟踪的同时估计传感器的空间偏差。文献[42]则介绍了该方法的基于杂波过程的一个变形, 以解决特定的空间失配问题, 已取得了良好效果。文献[49]第 3 章介绍了针对均匀分布和非均匀分布的传感器测量误差的多种空间配准方法, 既可以通过试验预先估计多传感器测量误差, 也可以在传感器执行探测任务的同时, 基于足够的测量数据估计传感器测量误差并进行补偿, 该方法已在实际应用中取得显著效益。

## 9.4 基于单目标融合扩展的多目标分布式融合

本节讨论将 9.2 节所描述的单目标分布式  $T^2F$  推广到多目标情况的分布式融合方法。

### 9.4.1 独立数据源的多目标 $T^2F$

与 9.2.2 节类似, 假设有  $s$  个独立数据源基于各自的局部传感器对多个目标进行跟踪。第  $j$  个数据源直到  $t_k$  时刻获得的多目标时序测量序列为

$$Z^{(k)}: Z_1^j, \dots, Z_k^j \quad k=1, 2, \dots \quad j=1, 2, \dots, s$$

其中,  $Z_l^j$  表示在  $t_l$  时刻 ( $l=1, \dots, k$ ) 第  $j$  个数据源获得的多目标测量集合。各数据源并不向  $T^2F$  站点传送直接测量信息, 而是向  $T^2F$  站点传送其基于自身测量产生的多目标航迹数据, 形式如下:

- 第  $j$  个数据源基于  $Z^{(k)}$  的  $t_{k+1}$  时刻的局部多目标航迹预测概率密度:

$$f_{k+1|k}^j(X) = f_{k+1|k}^j(X | Z^{(k)}) \quad j=1,2,\dots,s$$

- 第  $j$  个数据源基于  $Z^{(k+1)}$  产生的  $t_{k+1}$  时刻局部多目标航迹更新（后验）概率密度：

$$f_{k+1|k+1}^j(X) = f_{k+1|k+1}^j(X | Z^{(k+1)}) \quad j=1,2,\dots,s$$

若假设基于所有数据源提供的直到  $t_{k+1}$  时刻的多目标测量集合  $Z^{(k+1)} = \{Z^{(k+1)}, \dots, Z^{(k+1)}\}$  产生的多目标航迹后验密度和基于直到  $t_k$  时刻多目标测量集合  $Z^{(k)}$  产生的多目标航迹预测密度分别为： $f_{k+1|k+1}^j(X) = f_{k+1|k+1}^j(X | Z^{(k+1)})$  和  $f_{k+1|k}^j(X) = f_{k+1|k}^j(X | Z^{(k)})$ 。则 9.2.2 节中单一目标多独立数据源 T<sup>2</sup>F 公式 (9.10) 向多目标推广的 T<sup>2</sup>F 公式为<sup>[3]</sup>

$$f_{k+1|k+1}^j(X) \propto \frac{f_{k+1|k+1}^1(X)}{f_{k+1|k}^1(X)} \dots \frac{f_{k+1|k+1}^s(X)}{f_{k+1|k}^s(X)} f_{k+1|k}^j(X) \quad (9.87)$$

值得指出的是，式 (9.87) 中各跟踪数据源基于其独立获取测量集合产生的多目标航迹后验分布密度  $f_{k+1|k+1}^j(X)$  是  $t_{k+1}$  时刻多个目标状态及目标数量的联合分布密度，该联合分布密度的计算按照 9.3.2 节所描述的多目标随机分布密度的计算方法，是基于作为泛函的多目标概率密度  $f_{k|k}^j(X)$  对多目标随机集合  $X$ （作为该泛函的自变量函数）的导数和积分计算实现的。从联合概率密度中提取应用需要的目标数量，各目标的位置、速度、属性等信息见 9.3.1 节中联合多目标估计器 (JoM) 式 (9.52) 的描述，以及 9.3.3 节对 PHD 滤波一阶矩  $D_{k|k}(X | Z^{(k)})$  概念的描述，详见文献[7]。式 (9.87) 是具有独立跟踪源的多目标跟踪 T<sup>2</sup>F 的基本公式。如 9.2.2 节所述，该式是假设各跟踪源在每个时刻独立同步提供目标局部航迹导出的，该公式也可应用于异步航迹数据融合的情况，此时若每个跟踪源有自己的航迹生成周期和数据传输率，则 T<sup>2</sup>F 站点有多源航迹数据的采集时间  $t_1, \dots, t_k$  可以参照所有跟踪源局部航迹到达时间进行时间区间分割，确定近似的各融合的时刻，聚集产生各时刻的局部航迹集合。若某一融合时刻  $t_l$  只有  $s_l$  个跟踪源提供的航迹数据到达 T<sup>2</sup>F 站点，式 (9.87) 融合就只能采用  $s$  个跟踪源提供的局部航迹密度。

9.2.2 节所描述的近似方法同样可以应用到这里。假设各跟踪源向 T<sup>2</sup>F 站点不传送多目标航迹预测密度  $f_{k+1|k}^j(X)$ ，仅传送多目标航迹后验概率密度  $f_{k+1|k+1}^j(X)$ 。此时可假设所有跟踪源采用相同的多目标运动模型，于是 T<sup>2</sup>F 站点可基于上一周期各数据源报送的局部后验密度  $f_{k|k}^j(X)$ ，采用式 (9.48) 所示的多目标航迹密度预测方程，构建各跟踪源的多目标航迹预测密度：

$$f_{k+1|k}^j(X) = \int f_{k+1|k}(X | X') f_{k|k}^j(X') \delta X' \quad (9.88)$$

然后再应用式 (9.87) 获得  $t_{k+1}$  时刻的多目标 T<sup>2</sup>F 后验密度。

第二种选择是假设各跟踪源的预测航迹密度与  $T^2F$  站点的融合航迹预测密度相同,即

$$f_{k+1|k}^j(X) = f_{k+1|k}(X) \quad i=1,2,\dots,s$$

此时式 (9.87) 简化为

$$f_{k+1|k+1}(X) \propto f_{k+1|k+1}^1(X) \cdots f_{k+1|k+1}^s(X) f_{k+1|k}(X)^{1-s} \quad (9.89)$$

这就是单目标情况的“贝叶斯并联组合”公式 (9.14) 向多目标的推广。通常,式 (9.88) 和式 (9.89) 在计算上是不可行的,在 9.5.2 节中将给出近似计算方法。

### 9.4.2 非独立数据源的多目标 $T^2F$

如 9.2.3 节所述,非独立数据源的多目标  $T^2F$  主要面对某些传感器测量数据被重复计入某些数据源的情况。

假设某些跟踪源共用一些传感器,并已知哪些传感器测量被哪些数据源(跟踪源)共用的知识。与 9.2.3 节相同,定义  $t_{k+1}$  时刻的第  $j$  个跟踪源所使用的传感器测量集合为  $Z_{k+1}^j (j=1,\dots,s)$ ,所有  $s$  个跟踪源的测量集合为  $Z_{k+1} = Z_{k+1}^1 \cup \cdots \cup Z_{k+1}^s$ 。采用与图 9.3 相同的分解方法,将  $Z_{k+1}$  分解为  $s$  个相互独立的测量子集:

$$Z_{k+1}^1, Z_{k+1}^{12}, \dots, Z_{k+1}^{1s}$$

令交集  $Z_{k+1}^{(j)} = Z_{k+1}^j - Z_{k+1}^{1j} (j=2,\dots,s)$ ,则 9.2.3 节基于  $s$  个非独立(相关)的单目标融合航迹概率密度公式 (9.19) 的多目标形式为

$$f_{k+1|k+1}(X) \propto \frac{f_{k+1|k+1}^1(X)}{f_{k+1|k}^1(X)} \frac{f_{k+1|k+1}^2(X)}{f_{k+1|k}^2(X|Z)} \cdots \frac{f_{k+1|k+1}^s(X)}{f_{k+1|k}^s(X|Z)} f_{k+1|k}(X) \quad (9.90)$$

式 (9.90) 就是多相关跟踪系统多目标航迹概率密度融合公式,从中可以看出,第  $j$  个跟踪源必须知道它与第  $1,2,\dots,j-1$  个跟踪源共享了哪些传感器测量数据,以求取重复计入的测量交集  $Z_{k+1}^{(j)} (j=2,\dots,s)$ 。此外,每个跟踪源向  $T^2F$  站点除了传送  $f_{k+1|k+1}^j(X)$  和  $f_{k+1|k}^j(X)$  之外,还必须传送基于交集的预测密度  $f_{k+1|k}^j(X|Z)$ 。

一般情况下,式 (9.90) 在计算上也是不可行的。在 9.5.3 节和 9.5.4 节将介绍更多可行的近似方法。

### 9.4.3 多目标指数混合 (XM) 融合

9.2.5 节所述的单目标多源 XM 融合或 CI 融合是被融合航迹相关性未知或部分已知情况下  $T^2F$  的一种启发式(尝试式)方法, XM 是采用对被融合的概率密度进行指数加权的方法实现的。9.2.5 节的讨论也适合于多目标 XM 融合情况。

假设两个独立或相关跟踪源观测到多个目标,在  $t_{k+1}$  时刻,两个跟踪源向  $T^2F$  站点提供的多目标概率密度分别为  $f_{k+1|k+1}^0(X)$  和  $f_{k+1|k+1}^1(X)$ ,此时 9.2.5 节的单目标 XM 融合公式

(9.34) 可以推广为下述多目标形式<sup>[3]</sup>:

$$f_{k+1|k+1}^{\omega}(X) = \frac{f_{k+1|k+1}^0(X)^{1-\omega} f_{k+1|k+1}^1(X)^{\omega}}{\int f_{k+1|k+1}^0(Y)^{1-\omega} f_{k+1|k+1}^1(Y)^{\omega} \delta Y} \quad (9.91)$$

式(9.91)可理解为两被融合航迹相关性完全未知情况下的多目标航迹分布密度的通用融合公式。

与9.2.5节关于指数权值 $\omega$ 的优化选择的两种方法讨论类似,多目标XM融合最合理的指数权值 $\omega$ 的优化选择应该是:

$$\hat{\omega} = \arg \sup_{\omega} \sup_X f_{k+1|k+1}^{\omega}(X) \frac{c^{|X|}}{|X|!} \quad (9.92)$$

此时式(9.91)给出的多目标XM融合结果为

$$f_{k+1|k+1}^{XM}(X) = f_{k+1|k+1}^{\hat{\omega}}(X) \quad (9.93)$$

式(9.92)中,  $|X|$ 表示多目标随机过程 $X$ 中的目标数量,  $c$ 与9.3.1节中的定义相同,即 $c$ 是与单目标状态 $\mathbf{x}$ 的测量单位(分辨率)相同的一个固定常数,或者说其与估计的单目标状态精度相同。

式(9.91)和式(9.92)通常在计算上是不可行的,在9.5.5和9.5.6节将介绍这些公式更多计算上可行的近似方法。

## 9.5 基于CPHD/PHD滤波的多目标航迹融合公式

本节将对9.4节所描述的公式,导出基于CPHD/PHD滤波的、在计算上可行的多目标T<sup>2</sup>F方法,包括:

- ① 对多跟踪源独立条件下的多目标T<sup>2</sup>F公式(9.87)或式(9.89)的CPHD和PHD滤波方法;
- ② 对已知测量数据重复计入导致跟踪源相关的多目标T<sup>2</sup>F公式(9.90)的CPHD和PHD滤波方法;
- ③ 对相关性完全未知的任意跟踪源的多目标XM融合公式(9.91)的CPHD和PHD滤波方法。

### 9.5.1 基于CPHD滤波的独立跟踪源T<sup>2</sup>F公式

与9.4.1节假设类似,有 $s$ 个独立跟踪源采用各自专用的(独立的)传感器对多目标进行跟踪,并将各自产生的多目标局部航迹数据传送给T<sup>2</sup>F站点。设第 $j$ 个跟踪源对其专用的第 $j$ 组传感器采集的多目标测量数据采用9.3.4节的CPHD滤波方法(假设虚警模型为独立同分布)进行处理,并以下述统计分布密度形式传送给T<sup>2</sup>F站点:

- 基于直到 $t_{k+1}$ 时刻测量集合 $Z^{(k+1)}$ 密度的各跟踪源局部多目标航迹更新估计,形式为多目标的空分布密度 $s_{k+1|k}^j(\mathbf{x}) = s_{k+1|k}^j(\mathbf{x} | Z^{(k)})$ 和基数分布密度



$$p_{k+1|k+1}^j(n) = p_{k+1|k+1}^j(n | Z^{(k+1)}), \quad i=1,2,\dots,s;$$

- 基于  $Z^{(k)}$  的  $t_{k+1}$  时刻各跟踪源多目标局部航迹预测估计, 形式为多目标空间分布预测密度  $s_{k+1|k}^j(\mathbf{x}) = s_{k+1|k}^j(\mathbf{x} | Z^{(k)})$  和基数分布预测密度  $p_{k+1|k}^j(n) = p_{k+1|k}^j(n | Z^{(k)})$ ,  $i=1,2,\dots,s$ 。

由于假设各跟踪源产生的多目标局部航迹分布是 IIDC 过程, 故由式 (9.60) 可知各跟踪源提供的多目标航迹分布估计和预测密度分别为

$$f_{k+1|k+1}^j(X) = |X|! p_{k+1|k+1}^j(|X|) s_{k+1|k+1}^{X^j} \quad j=1,2,\dots,s \quad (9.94)$$

$$f_{k+1|k}^j(X) = |X|! p_{k+1|k}^j(|X|) s_{k+1|k}^{X^j} \quad j=1,2,\dots,s \quad (9.95)$$

其中,  $s^{X^j}$  为由式 (9.61) 定义的多目标  $X^j$  空间密度;  $p(|X|) = p(n)$  为由式 (9.44) 定义的多目标基数分布密度。

于是, 可以证明从式 (9.87) 获得的全局多目标  $T^2F$  分布也是一个 IIDC 过程:

$$f_{k+1|k+1}(X) = |X|! p_{k+1|k+1}(|X|) s_{k+1|k+1}^X \quad (9.96)$$

其中, 融合的多目标基数分布密度为

$$p_{k+1|k+1}(n) = \frac{1}{\mu_{k+1|k+1}} \frac{p_{k+1|k+1}^1(n)}{p_{k+1|k}^1(n)} \dots \frac{p_{k+1|k+1}^s(n)}{p_{k+1|k}^s(n)} \sigma_{k+1|k+1}^n p_{k+1|k}(n) \quad (9.97)$$

融合的多目标航迹空间分布密度为

$$s_{k+1|k+1}(\mathbf{x}) = \frac{1}{\sigma_{k+1|k+1}} \frac{s_{k+1|k+1}^1(\mathbf{x})}{s_{k+1|k}^1(\mathbf{x})} \dots \frac{s_{k+1|k+1}^s(\mathbf{x})}{s_{k+1|k}^s(\mathbf{x})} s_{k+1|k}(\mathbf{x}) \quad (9.98)$$

在式 (9.97) 和式 (9.98) 中, 归一化常数为

$$\mu_{k+1|k+1} = \sum_{n \geq 0} \frac{p_{k+1|k+1}^1(n)}{p_{k+1|k}^1(n)} \dots \frac{p_{k+1|k+1}^s(n)}{p_{k+1|k}^s(n)} \sigma_{k+1|k+1}^n p_{k+1|k}(n) \quad (9.99)$$

$$\sigma_{k+1|k+1} = \int \frac{s_{k+1|k+1}^1(\mathbf{x})}{s_{k+1|k}^1(\mathbf{x})} \dots \frac{s_{k+1|k+1}^s(\mathbf{x})}{s_{k+1|k}^s(\mathbf{x})} s_{k+1|k}(\mathbf{x}) d\mathbf{x} \quad (9.100)$$

证明如下:

首先,  $T^2F$  站点基于  $s$  个跟踪源传送来的多目标局部航迹分布是 IIDC 过程 (9.94) 和 (9.95), 与单目标独立跟踪源  $T^2F$  类似, 此时多目标  $T^2F$  航迹预测密度也是 IIDC 过程:

$$f_{k+1|k}(X) = |X|! p_{k+1|k}(|X|) s_{k+1|k}^X \quad (9.101)$$

将式 (9.94)、式 (9.95)、式 (9.101) 代入式 (9.87) 得:

$$f_{k+1|k+1}(X) \propto \frac{f_{k+1|k+1}^1(X)}{f_{k+1|k}^1(X)} \frac{f_{k+1|k+1}^2(X)}{f_{k+1|k}^2(X)} \dots \frac{f_{k+1|k+1}^s(X)}{f_{k+1|k}^s(X)} f_{k+1|k}(X) \quad (9.102)$$

$$= \frac{|X|! p_{k+1|k+1}^1(|X|) s_{k+1|k+1}^{X^1} \dots |X|! p_{k+1|k+1}^s(|X|) s_{k+1|k+1}^{X^s}}{|X|! p_{k+1|k}^1(|X|) s_{k+1|k}^{X^1} \dots |X|! p_{k+1|k}^s(|X|) s_{k+1|k}^{X^s}} |X|! p_{k+1|k}(|X|) s_{k+1|k}^X \quad (9.103)$$

$$= |X|! \frac{p_{k+1|k+1}^1(|X|)}{p_{k+1|k}^1(|X|)} \dots \frac{p_{k+1|k+1}^s(|X|)}{p_{k+1|k}^s(|X|)} p_{k+1|k}(|X|) \left( \frac{1}{s_{k+1|k}} \dots \frac{s_{k+1|k+1}}{s_{k+1|k}} s_{k+1|k}^X \right)^X \quad (9.104)$$

$$\propto |X|! p'_{k+1|k+1}(|X|) s_{k+1|k+1}^{X'} \quad (9.105)$$

其中, 概率密度  $p'_{k+1|k+1}(|X|)$  和基数密度  $s'_{k+1|k+1}(\mathbf{x})$  分别表示为

$$p'_{k+1|k+1}(n) \propto \frac{p_{k+1|k+1}^1(n)}{p_{k+1|k}^1(n)} \dots \frac{p_{k+1|k+1}^s(n)}{p_{k+1|k}^s(n)} p_{k+1|k}(n) \quad (9.106)$$

$$s'_{k+1|k+1}(\mathbf{x}) \propto \frac{s_{k+1|k+1}^1(\mathbf{x})}{s_{k+1|k}^1(\mathbf{x})} \dots \frac{s_{k+1|k+1}^s(\mathbf{x})}{s_{k+1|k}^s(\mathbf{x})} s_{k+1|k}(\mathbf{x}) \quad (9.107)$$

此二比例式与等式 (9.97)、(9.98) 极其相似。下面给出等式 (9.97)、(9.98) 的推导过程:

取

$$f(X) = f_{k+1|k+1}(X) = \frac{f_{k+1|k+1}^1(X)}{f_{k+1|k}^1(X)} \frac{f_{k+1|k+1}^2(X)}{f_{k+1|k}^2(X)} \dots \frac{f_{k+1|k+1}^s(X)}{f_{k+1|k}^s(X)} f_{k+1|k}(X)$$

由多目标概率分布密度的泛函积分公式 (9.54), 可得:

$$\int f(X) \delta X = \sum_{n=0}^{\infty} \frac{1}{n!} \int f_{k+1|k+1}(\mathbf{x}_1, \dots, \mathbf{x}_n) d\mathbf{x}_1 \dots d\mathbf{x}_n$$

将式 (9.94)、式 (9.95) 和式 (9.101) 代入  $f_{k+1|k+1}(X)$  的上述表达式, 并进行积分, 可得:

$$\int f(X) \delta X = \sum_{n=0}^{\infty} \frac{1}{n!} \frac{p_{k+1|k+1}^1(n)}{p_{k+1|k}^1(n)} \dots \frac{p_{k+1|k+1}^s(n)}{p_{k+1|k}^s(n)} p_{k+1|k}(n) \int \frac{s_{k+1|k+1}^{X^1}}{s_{k+1|k}^{X^1}} \dots \frac{s_{k+1|k+1}^{X^s}}{s_{k+1|k}^{X^s}} s_{k+1|k}^X d\mathbf{x}_1 \dots d\mathbf{x}_n$$

再由式 (9.61) 可知:

$$s^{X^j} = s(\mathbf{x}_1) \dots s(\mathbf{x}_n) \quad j=1, 2, \dots, s$$

于是,

$$\begin{aligned} & \int \frac{s_{k+1|k+1}^{X^1}}{s_{k+1|k}^{X^1}} \dots \frac{s_{k+1|k+1}^{X^s}}{s_{k+1|k}^{X^s}} s_{k+1|k}^X d\mathbf{x}_1 \dots d\mathbf{x}_n \\ &= \left[ \int \frac{s_{k+1|k+1}^1(\mathbf{x}_1)}{s_{k+1|k}^1(\mathbf{x}_1)} \dots \frac{s_{k+1|k+1}^s(\mathbf{x}_1)}{s_{k+1|k}^s(\mathbf{x}_1)} s_{k+1|k}(\mathbf{x}_1) d\mathbf{x}_1 \right] \dots \left[ \int \frac{s_{k+1|k+1}^1(\mathbf{x}_n)}{s_{k+1|k}^1(\mathbf{x}_n)} \dots \frac{s_{k+1|k+1}^s(\mathbf{x}_n)}{s_{k+1|k}^s(\mathbf{x}_n)} s_{k+1|k}(\mathbf{x}_n) d\mathbf{x}_n \right] \\ &= \left[ \int \frac{s_{k+1|k+1}^1(\mathbf{x})}{s_{k+1|k}^1(\mathbf{x})} \dots \frac{s_{k+1|k+1}^s(\mathbf{x})}{s_{k+1|k}^s(\mathbf{x})} s_{k+1|k}(\mathbf{x}) d\mathbf{x} \right]^n \triangleq \sigma_{k+1|k+1}^n \end{aligned}$$

这里的  $\sigma_{k+1|k+1}$  即为式 (9.100)。

于是, 可得:

$$\int f(X) \delta X = \sum_{n=0}^{\infty} \frac{p_{k+1|k+1}(n)}{p_{k+1|k}(n)} \cdots \frac{p_{k+1|k+1}(n)}{p_{k+1|k}(n)} p_{k+1|k}(n) \sigma_{k+1|k+1}^n$$

$$\triangleq \mu_{k+1|k+1}$$

这里的  $\mu_{k+1|k+1}$  即为式 (9.99)。

再注意式 (9.104) 和式 (9.105), 就得到独立跟踪源的多目标 T<sup>2</sup>F 公式 (9.87) 的归一化形式:

$$f_{k+1|k+1}(X) = \frac{f_{k+1|k+1}(X)}{\int f_{k+1|k+1}(X) \delta X} = \frac{|X|! p'_{k+1|k+1}(|X|) s_{k+1|k+1}^X}{\mu_{k+1|k+1}} = n! p_{k+1|k+1}(n) s_{k+1|k+1}^X \quad (9.108)$$

此式即为式 (9.96), 其中,  $p_{k+1|k+1} = p'_{k+1|k+1} \sigma_{k+1|k+1}^n / \mu_{k+1|k+1}$ ,  $s_{k+1|k+1} = s'_{k+1|k+1} / \sigma_{k+1|k+1}$  分别为式 (9.97) 和式 (9.98), 至此证明完毕。

假设采用近似式  $p_{k+1|k}^j(n) = p_{k+1|k}(n)$  和  $s_{k+1|k}^j(x) = s_{k+1|k}(x)$  ( $j=1, 2, \dots, s$ ), 则利用式 (9.89) 所示的贝叶斯并联组合公式可以将这两个分布的 CPHD 滤波近似为

$$p_{k+1|k+1}(n) = \frac{1}{\mu_{k+1|k+1}} p_{k+1|k+1}^1(n) \cdots p_{k+1|k+1}^s(n) \sigma_{k+1|k+1}^n p_{k+1|k}(n)^{1-s} \quad (9.109)$$

$$s_{k+1|k+1}(x) = \frac{1}{\sigma_{k+1|k+1}} s_{k+1|k+1}^1(x) \cdots s_{k+1|k+1}^s(x) s_{k+1|k}(x)^{1-s} \quad (9.110)$$

其中,

$$\mu_{k+1|k+1} = \sum_{n \geq 0} p_{k+1|k+1}^1(n) \cdots p_{k+1|k+1}^s(n) \sigma_{k+1|k+1}^n p_{k+1|k}(n) \quad (9.111)$$

$$\sigma_{k+1|k+1} = \int s_{k+1|k+1}^1(x) \cdots s_{k+1|k+1}^s(x) s_{k+1|k}(x)^{1-s} dx \quad (9.112)$$

值得注意的是: 式 (9.109) 和式 (9.110) 就是 9.3.5 节所提及的合理的多传感器 CPHD 和 PHD 滤波的一个较好的近似<sup>[39]</sup>。

## 9.5.2 基于 PHD 滤波的独立跟踪源 T<sup>2</sup>F 公式

假设跟踪源采用 PHD 滤波而不是 CPHD 滤波, 则各跟踪源向 T<sup>2</sup>F 站点传送的仅是多目标后验分布密度  $f_{k+1|k+1}^j(X | Z^{(k+1)})$  的一阶矩  $D_{k+1|k+1}^j(x | Z^{(k+1)})$ ,  $j=1, 2, \dots, s$ 。此时 T<sup>2</sup>F 站点的 PHD 融合公式为

$$D_{k+1|k+1}(x) = \frac{D_{k+1|k+1}^1(x)}{D_{k+1|k}^1(x)} \frac{D_{k+1|k+1}^2(x)}{D_{k+1|k}^2(x)} \cdots \frac{D_{k+1|k+1}^s(x)}{D_{k+1|k}^s(x)} D_{k+1|k}(x) \quad (9.113)$$

证明如下:

PHD 滤波假设各跟踪源产生的局部多目标航迹分布为泊松过程, 即

$$f_{k+1|k}(X) = e^{-N_{k+1|k}} D_{k+1|k}^X \quad (9.114)$$

$$f_{k+1|k+1}^j(X) = e^{-N_{k+1|k+1}^j} D_{k+1|k+1}^{X^j} \quad j=1,2,\dots,s \quad (9.115)$$

$$f_{k+1|k}^j(X) = e^{-N_{k+1|k}^j} D_{k+1|k}^{X^j} \quad j=1,2,\dots,s \quad (9.116)$$

则 T<sup>2</sup>F 站点对各独立跟踪源的多目标局部航迹的融合航迹分布也是一个泊松过程:

$$f_{k+1|k+1}(X) = e^{-N_{k+1|k+1}} D_{k+1|k+1}^X \quad (9.117)$$

其中,

$$D_{k+1|k+1}(x) = \frac{D_{k+1|k+1}^1(x)}{D_{k+1|k}^1(x)} \frac{D_{k+1|k+1}^2(x)}{D_{k+1|k}^2(x)} \dots \frac{D_{k+1|k+1}^s(x)}{D_{k+1|k}^s(x)} D_{k+1|k}(x) \quad (9.118)$$

$$N_{k+1|k+1} = \int D_{k+1|k+1}(x) dx \quad (9.119)$$

事实上, 将式 (9.114) ~ 式 (9.116) 代入式 (9.87), 可以得到:

$$f_{k+1|k+1}(X) \propto \frac{f_{k+1|k+1}^1(X)}{f_{k+1|k}^1(X)} \dots \frac{f_{k+1|k+1}^s(X)}{f_{k+1|k}^s(X)} f_{k+1|k}(X) \quad (9.120)$$

$$= \frac{e^{-N_{k+1|k+1}^1} D_{k+1|k+1}^{X^1}}{e^{-N_{k+1|k}^1} D_{k+1|k}^{X^1}} \dots \frac{e^{-N_{k+1|k+1}^s} D_{k+1|k+1}^{X^s}}{e^{-N_{k+1|k}^s} D_{k+1|k}^{X^s}} e^{-N_{k+1|k}} D_{k+1|k}^X \quad (9.121)$$

我们注意到每个跟踪源都对多目标过程  $X$  进行跟踪, 于是  $X^1 = X^2 = \dots = X^s = X$ , 由式 (9.59) 得到  $D^{X^j}(x) = \prod_{x \in X^j} D^j(x) = \prod_{x \in X} D^j(x) = [D^j(x)]^X$ , 将其代入式 (9.121) 中各  $D_{k+1|k+1}^{X^i}$ 、 $D_{k+1|k}^{X^i}$  及  $D_{k+1|k}^X$ , 可得:

$$f_{k+1|k+1}(X) \propto e^{-\sum_{j=1}^s \left( N_{k+1|k+1}^j - N_{k+1|k}^j \right) - N_{k+1|k}} \left( \frac{D_{k+1|k+1}^1}{D_{k+1|k}^1} \dots \frac{D_{k+1|k+1}^s}{D_{k+1|k}^s} D_{k+1|k}^X \right)^X \quad (9.122)$$

$$\triangleq e^{-N_{k+1|k+1}} D_{k+1|k+1}^X \quad (9.123)$$

其中,  $D_{k+1|k+1}$  即表示式 (9.118),  $N_{k+1|k+1}$  与式 (9.119) 形式相同。若各跟踪源预测目标数与估计目标数相同, 即  $N_{k+1|k+1}^j = N_{k+1|k}^j$  ( $j=1,2,\dots,s$ ), 则融合目标数也与预测目标数相同, 即  $N_{k+1|k+1} \approx N_{k+1|k}$ 。

我们注意到, 式 (9.118) 并不能简化为单一目标的情况。例如, 在假设  $D_{k+1|k}^i(x) = D_{k+1|k}(x)$  ( $i=1,2,\dots,s$ ) 的情况下, 式 (9.118) 变为

$$D_{k+1|k+1}(x) = D_{k+1|k+1}^1(x) \dots D_{k+1|k+1}^s(x) D_{k+1|k}(x)^{1-s} \quad (9.124)$$

对于单目标贝叶斯递推滤波来说  $N=1$ , 此时,  $f_{k+1|k}(x) = D_{k+1|k}(x)$  和  $D_{k+1|k+1}^j(x) = f_{k+1|k+1}^j(x)$  ( $j=1,2,\dots,s$ ) 的积分都等于 1, 并且  $D_{k+1|k+1}(x)$  的积分也等于 1; 但从泊松分布定义式 (9.58) 和 (9.59) 来看, 并不能得到这样的结论。在不存在漏检和虚警的情况下, 容易证明式 (9.124) 等同于式 (9.89) 给出的“贝叶斯并联组合”, 但是当存在漏检和虚警时, 二者并不等同。

我们注意到,在存在漏检和虚警的情况下,基于独立跟踪源的CPHD的 $T^2F$ 近似公式(9.97)和(9.98)能够简化为单一目标航融合公式,而式(9.118)在目标较少的情况下无法给出较精确的 $T^2F$ 近似公式,由此可以看出基于PHD滤波的 $T^2F$ 近似的局限性。

假设第 $j$ 个跟踪源采用的PHD滤波更新公式是:

$$\bar{D}_{k+1|k+1}^j(\mathbf{x}) = \bar{L}_{Z_{k+1}}^j(\mathbf{x}) \bar{D}_{k+1|k}^j(\mathbf{x})$$

其中,  $\bar{L}_{Z_{k+1}}^j(\mathbf{x})$  是如式(9.65)中所定义的第 $j$ 个跟踪源 $t_{k+1}$ 时刻测量集合 $Z_{k+1}^j(\mathbf{x})$ 的似然函数,则式(9.118)变为

$$D_{k+1|k+1}(\mathbf{x}) = \bar{L}_{Z_{k+1}}^1(\mathbf{x}) \cdots \bar{L}_{Z_{k+1}}^s(\mathbf{x}) D_{k+1|k}(\mathbf{x}) \quad (9.125)$$

该公式是基于似然函数的PHD滤波更新的 $T^2F$ 公式<sup>[43]</sup>。当目标数量较少时,该更新公式也可能不准确。

### 9.5.3 基于CPHD滤波和PHD滤波的相关跟踪源 $T^2F$ 公式

假设某些跟踪源共用一些传感器,并已知共用情况。共用一些传感器的跟踪源使用CPHD滤波或PHD滤波处理这些共用传感器测量数据。如9.4.2节中的假设, $t_{k+1}$ 时刻第 $j$ 个跟踪源使用的传感器测量为 $Z_{k+1}^j(j=1, \dots, s)$ ,所有 $s$ 个跟踪源的测量集合为 $Z_{k+1} = Z_{k+1}^1 \cup \cdots \cup Z_{k+1}^s$ 。将 $Z_{k+1}$ 分解为 $s$ 个相互独立的测量子集如下:

$$Z_{k+1}^1, Z_{k+1}^{12}, \dots, Z_{k+1}^{1s}$$

并令交集为

$$Z_{k+1}^{(j)} = Z_{k+1}^j - Z_{k+1}^{1j}, \quad Z_{k+1}^{(1)} = Z_{k+1}^1 \quad j=2, \dots, s$$

设第 $j$ 个跟踪源向 $T^2F$ 站点提供 $t_{k+1}$ 时刻的多目标航迹的空间分布 $s_{k+1|k+1}^j$ 和基于交集的预测空间分布 $s_{k+1|k}^j(\mathbf{x} | Z^{(j)})$ 以及 $t_{k+1}$ 时刻的航迹基数分布 $p_{k+1|k+1}^j(n)$ 和基于交集的预测基数分布 $p_{k+1|k}^j(n | Z^{(j)})$ 。则9.4.2节中非独立跟踪源的 $T^2F$ 航迹密度公式(9.90)可以写为如下形式:

(1) 基于CPHD滤波的多目标航迹融合密度形式。

设 $s$ 个跟踪源向 $T^2F$ 站点提供的局部航迹分布是IIDC过程,即

$$f_{k+1|k}(X) = |X|! p_{k+1|k}(|X|) s_{k+1|k}^X \quad (9.126)$$

$$\bar{f}_{k+1|k+1}^j(X) = |X|! p_{k+1|k+1}^j(|X|) s_{k+1|k+1}^{X^j} \quad (9.127)$$

$$\bar{f}_{k+1|k}^j(X | Z^{(j)}) = |X|! p_{k+1|k}^j(|X|) s_{k+1|k}^{X^j} \quad (9.128)$$

其中,

$$p_{k+1|k}^j(n) = p_{k+1|k}^j(n | Z^{(k)}) \quad j=1, 2, \dots, s \quad (9.129)$$

$$s_{k+1|k}^j(\mathbf{x}) = s_{k+1|k}^j(\mathbf{x} | Z^{(k)}) \quad j=1, 2, \dots, s \quad (9.130)$$

式 (9.126) 是 T<sup>2</sup>F 站点基于上一  $t_k$  时刻 CPHD 滤波结果和多目标预测公式 (9.70) ~ (9.73) 获得的, 则可以证明相关跟踪源情况的多目标 T<sup>2</sup>F 分布密度也是一个 IIDC 过程:

$$f_{k+1|k+1}(X) = |X|! p_{k+1|k+1}(|X|) s_{k+1|k+1}^X \quad (9.131)$$

其中,

$$p_{k+1|k+1}(n) = \frac{1}{\mu_{k+1|k+1}} \frac{p_{k+1|k+1}^{(1)}(n)}{p_{k+1|k}^{(1)}(n)} \frac{p_{k+1|k+1}^{(2)}(n)}{p_{k+1|k}^{(2)}(n|Z)} \cdots \frac{p_{k+1|k+1}^{(s)}(n)}{p_{k+1|k}^{(s)}(n|Z)} \sigma_{k+1|k+1}^n p_{k+1|k}(n) \quad (9.132)$$

$$s_{k+1|k+1}(\mathbf{x}) = \frac{1}{\sigma_{k+1|k+1}} \frac{s_{k+1|k+1}^{(1)}(\mathbf{x})}{s_{k+1|k}^{(1)}(\mathbf{x})} \frac{s_{k+1|k+1}^{(2)}(\mathbf{x})}{s_{k+1|k}^{(2)}(\mathbf{x}|Z)} \cdots \frac{s_{k+1|k+1}^{(s)}(\mathbf{x})}{s_{k+1|k}^{(s)}(\mathbf{x}|Z)} s_{k+1|k}(\mathbf{x}) \quad (9.133)$$

式 (9.132) 和式 (9.133) 中:

$$\mu_{k+1|k+1} = \sum_{n \geq 0} \frac{p_{k+1|k+1}^{(1)}(n)}{p_{k+1|k}^{(1)}(n)} \frac{p_{k+1|k+1}^{(2)}(n)}{p_{k+1|k}^{(2)}(n|Z)} \cdots \frac{p_{k+1|k+1}^{(s)}(n)}{p_{k+1|k}^{(s)}(n|Z)} \sigma_{k+1|k+1}^n p_{k+1|k}(n) \quad (9.134)$$

$$\sigma_{k+1|k+1} = \int \frac{s_{k+1|k+1}^{(1)}(\mathbf{x})}{s_{k+1|k}^{(1)}(\mathbf{x})} \frac{s_{k+1|k+1}^{(2)}(\mathbf{x})}{s_{k+1|k}^{(2)}(\mathbf{x}|Z)} \cdots \frac{s_{k+1|k+1}^{(s)}(\mathbf{x})}{s_{k+1|k}^{(s)}(\mathbf{x}|Z)} s_{k+1|k}(\mathbf{x}) d\mathbf{x} \quad (9.135)$$

证明推导过程与 9.5.1 节基于 CPHD 滤波的独立跟踪源 T<sup>2</sup>F 近似公式的推导相同。

(2) 基于 PHD 滤波的多目标航迹融合密度形式。

与 9.5.2 节描述的基于 PHD 滤波的独立跟踪源 T<sup>2</sup>F 公式 (9.118) 类似, 可以导出基于 PHD 滤波的相关跟踪源 T<sup>2</sup>F 公式为

$$D_{k+1|k+1}(\mathbf{x}) = \frac{D_{k+1|k+1}^{(1)}(\mathbf{x})}{D_{k+1|k}^{(1)}(\mathbf{x})} \frac{D_{k+1|k+1}^{(2)}(\mathbf{x})}{D_{k+1|k}^{(2)}(\mathbf{x}|Z)} \cdots \frac{D_{k+1|k+1}^{(s)}(\mathbf{x})}{D_{k+1|k}^{(s)}(\mathbf{x}|Z)} D_{k+1|k}(\mathbf{x}) \quad (9.136)$$

我们注意到, 式 (9.136) 中仅将式 (9.118) 中的  $D_{k+1|k}^j(\mathbf{x}) = D_{k+1|k}^j(\mathbf{x})$  替换为  $D_{k+1|k}^j(\mathbf{x}|Z) = D_{k+1|k}^j(\mathbf{x}|Z^{(k)})$ ,  $j=2, \dots, s$ 。

#### 9.5.4 基于 CPHD 滤波的多目标分布密度的指数混合 (XM) 融合近似

多目标 XM 融合公式 (9.91) 在独立同分布 IIDC 杂波过程下的特定形式就是本节所描述的基于 CPHD 滤波的 XMT<sup>2</sup>F<sup>[4-6]</sup>形式。假设采用 CPHD 滤波的两个跟踪源观测到多个目标。在  $t_{k+1}$  时刻第一个跟踪源提供多目标航迹的空间分布  $s_{k+1|k+1}^{(0)}(\mathbf{x})$  和目标数量 (基数) 分布  $p_{k+1|k+1}^{(0)}(n)$ , 第二个跟踪源提供多目标航迹的空间分布  $s_{k+1|k+1}^{(1)}(\mathbf{x})$  和目标数量 (基数) 分布  $p_{k+1|k+1}^{(1)}(n)$ 。

假设每个跟踪源向 T<sup>2</sup>F 站点提供的局部多目标航迹分布为 IIDC 过程。

$$f_{k+1|k+1}^0(X) = |X|! p_{k+1|k+1}^0(|X|) s_{k+1|k+1}^{X^0} \quad (9.137)$$

$$f_{k+1|k+1}^1(X) = |X|! p_{k+1|k+1}^1(|X|) s_{k+1|k+1}^{X^1} \quad (9.138)$$

我们注意多目标概率分布的泛函积分公式 (9.54) 以及上述两跟踪源提供的多目标局

部航迹分布的 IIDC 过程式 (9.137)、(9.138), 再取  $f(X) = f_{k+1|k+1} = f_{k+1|k+1}^{0^{1-\omega}} f_{k+1|k+1}^{1^\omega}$ , 并注意  $s^X$  的定义式 (9.61), 则多目标 XM 融合公式 (9.91) 的分母成为

$$\begin{aligned} \int f(X) \delta X &= \sum_{n=0}^{\infty} \frac{1}{n!} \int f_{k+1|k+1}(x_1, \dots, x_n) dx_1 \cdots dx_n \\ &= \sum_{n=0}^{\infty} \frac{1}{n!} \left[ n! p_{k+1|k+1}^0(n) \right]^{1-\omega} \left[ n! p_{k+1|k+1}^1(n) \right]^\omega \int \left[ s_{k+1|k+1}^{X^0} \right]^{1-\omega} \left[ s_{k+1|k+1}^{X^1} \right]^\omega dx_1 \cdots dx_n \\ &= \sum_{n=0}^{\infty} \left[ p_{k+1|k+1}^0(n)^{1-\omega} p_{k+1|k+1}^1(n)^\omega \right] \int s_{k+1|k+1}^0(x_1)^{1-\omega} s_{k+1|k+1}^1(x_1)^\omega \cdots s_{k+1|k+1}^0(x_n)^{1-\omega} s_{k+1|k+1}^1(x_n)^\omega dx_1 \cdots dx_n \\ &= \sum_{n=0}^{\infty} \left[ p_{k+1|k+1}^0(n)^{1-\omega} p_{k+1|k+1}^1(n)^\omega \right] \left[ \int s_{k+1|k+1}^0(x)^{1-\omega} s_{k+1|k+1}^1(x)^\omega dx \right]^n \\ &= \sum_{n=0}^{\infty} \left[ p_{k+1|k+1}^0(n)^{1-\omega} p_{k+1|k+1}^1(n)^\omega \right] \left[ \sigma_{k+1|k+1}^\omega \right]^n \\ &= \mu_{k+1|k+1}^\omega \end{aligned} \quad (9.139)$$

这里,

$$\sigma_{k+1|k+1} = \int s_{k+1|k+1}^0(x)^{1-\omega} s_{k+1|k+1}^1(x)^\omega dx \quad (9.140)$$

$$\mu_{k+1|k+1}^\omega = \sum_{n=0}^{\infty} \left[ p_{k+1|k+1}^0(n)^{1-\omega} p_{k+1|k+1}^1(n)^\omega \right] \left[ \sigma_{k+1|k+1}^\omega \right]^n \quad (9.141)$$

我们再注意式 (9.91) 的分子:

$$\begin{aligned} f_{k+1|k+1}^0(X)^{1-\omega} f_{k+1|k+1}^1(X)^\omega &= \left[ |X|! p_{k+1|k+1}^0(|X|) s_{k+1|k+1}^{X^0} \right]^{1-\omega} \left[ |X|! p_{k+1|k+1}^1(|X|) s_{k+1|k+1}^{X^1} \right]^\omega \\ &= n! \left[ p_{k+1|k+1}^0(n)^{1-\omega} p_{k+1|k+1}^1(n)^\omega \right] \left[ s_{k+1|k+1}^0 \quad s_{k+1|k+1}^1 \right]^\omega \end{aligned}$$

这样一来, 多目标 XM 融合公式 (9.91) 成为

$$\begin{aligned} f_{k+1|k+1}^\omega(X) &= \frac{f_{k+1|k+1}^0(X)^{1-\omega} f_{k+1|k+1}^1(X)^\omega}{\int f_{k+1|k+1}^0(Y)^{1-\omega} f_{k+1|k+1}^1(Y)^\omega \delta Y} \\ &= \frac{n!}{\mu_{k+1|k+1}^\omega} \left[ p_{k+1|k+1}^0(n)^{1-\omega} p_{k+1|k+1}^1(n)^\omega \right] \left[ s_{k+1|k+1}^0 \quad s_{k+1|k+1}^1 \right]^\omega \\ &\triangleq n! p_{k+1|k+1}^\omega(n) \left[ s_{k+1|k+1}^\omega(x) \right]^n \end{aligned} \quad (9.142)$$

即多目标融合分布  $f_{k+1|k+1}(X)$  也是一个 IIDC 过程。其中,

$$p_{k+1|k+1}^{\omega}(n) = \frac{1}{\mu_{k+1|k+1}^{\omega}} \left[ p_{k+1|k+1}^0(n)^{1-\omega} p_{k+1|k+1}^1(n)^{\omega} \right] \left[ \sigma_{k+1|k+1}^{\omega} \right]^n \quad (9.143)$$

$$s_{k+1|k+1}^{\omega}(x) = \frac{1}{\sigma_{k+1|k+1}^{\omega}} s_{k+1|k+1}^0(x)^{1-\omega} s_{k+1|k+1}^1(x)^{\omega} \quad (9.144)$$

式(9.143)和式(9.144)就是基于CPHD滤波的两局部多目标分布密度的指数融合(XM)融合的近似公式。

对于指数权值 $\omega$ 的优化选择,如9.4.3节所述的式(9.92),在这里的表示形式是:

$$\hat{\omega} = \arg \sup_{\omega} \sup_X f_{k+1|k+1}^{\omega}(X) \frac{c^{|X|}}{|X|!} = \arg \sup_{\omega} \sup_X p_{k+1|k+1}(|X|)(cs_{k+1|k+1})^X \quad (9.145)$$

其中 $c$ 的概念与式(9.92)相同,是一个与目标状态 $x$ 的传感器测量分辨率相同的固定参数。

式(9.145)在计算上的可行性仍较差。我们注意到,式(9.91)所表述的多目标航迹的指数混合(XM)融合通用公式也被称为“Chernoff融合”,于是我们可以基于Chernoff融合信息的定义式(9.35),考虑求取优化指数权值 $\omega$ 的一个近似方法:

首先,运用Chernoff融合优化两个跟踪源多目标 $T^2F$ 的空间分布密度,选择指数权值 $\hat{\omega}_1$ :

$$\hat{\omega}_1 = \arg \inf_{\omega} \int_0^1 s_{k+1|k+1}^{\omega}(x)^{1-\omega} s_{k+1|k+1}^1(x)^{\omega} dx \quad (9.146)$$

然后,设定:

$$\hat{\sigma} = \int_0^1 s_{k+1|k+1}^{\omega}(x)^{1-\hat{\omega}_1} s_{k+1|k+1}^1(x)^{\hat{\omega}_1} dx \quad (9.147)$$

再次将Chernoff融合用于该多目标 $T^2F$ 的基数分布,优化选择指数权值 $\hat{\omega}_2$ :

$$\hat{\omega}_2 = \arg \inf_{\omega} \sum_{n=0}^{\infty} \left[ p_{k+1|k+1}^0(n)^{1-\omega} p_{k+1|k+1}^1(n)^{\omega} \right] \hat{\sigma}^n \quad (9.148)$$

最后,获得最终的基于CPHD滤波的多目标XM融合分布为

$$p_{k+1|k+1}^{XM}(n) = p_{k+1|k+1}^{\hat{\omega}_2}(n), \quad s_{k+1|k+1}^{XM}(x) = s_{k+1|k+1}^{\hat{\omega}_1}(x) \quad (9.149)$$

文献[5,6,44]运用该Chernoff融合优化的指数权值 $\hat{\omega}_1$ 、 $\hat{\omega}_2$ 实现了式(9.143)和式(9.144)以及基于CPHD滤波的两跟踪源多目标XM融合公式(9.142)~式(9.144),并认为这是一个广泛可用的指数权值优化方法,同时验证了这些公式能给出良好的分布式融合性能。

### 9.5.5 基于PHD滤波的多目标分布密度的指数混合(XM)融合近似

两跟踪源多目标分布密度的XM融合公式(9.91)的PHD滤波近似形式可写成:

$$D_{k+1|k+1}^{\omega}(x) = D_{k+1|k+1}^0(x)^{1-\omega} D_{k+1|k+1}^1(x)^{\omega} \quad (9.150)$$

在实际应用中,假设两个跟踪源的多目标分布为泊松过程(见式(9.58)):

$$f_{k+1|k+1}^0(X) = e^{-N_{k+1|k+1}^0} D_{k+1|k+1}^{X^0} \quad (9.151)$$

$$f_{k+1|k+1}^1(X) = e^{-N_{k+1|k+1}^1} D_{k+1|k+1}^{X^1} \quad (9.152)$$



按式 (9.91) 可得:

$$f_{k+1|k+1}(X) \propto \left( e^{-\overset{0}{N}_{k+1|k+1}} D_{k+1|k+1}^{X^0} \right)^{1-\omega} \left( e^{-\overset{1}{N}_{k+1|k+1}} D_{k+1|k+1}^{X^1} \right)^{\omega} \quad (9.153)$$

$$= e^{-(1-\omega)\overset{0}{N}_{k+1|k+1} - \omega\overset{1}{N}_{k+1|k+1}} \left( \overset{0}{D}_{k+1|k+1}^{(1-\omega)} \overset{1}{D}_{k+1|k+1}^{\omega} \right)^X \quad (9.154)$$

$$\triangleq e^{-\overset{\omega}{N}_{k+1|k+1}} \left[ \overset{\omega}{D}_{k+1|k+1} \right]^X \quad (9.155)$$

其中,  $\overset{\omega}{D}_{k+1|k+1}(\mathbf{x})$  如式 (9.150) 所示, 而

$$\overset{\omega}{N}_{k+1|k+1} = \int \overset{0}{D}_{k+1|k+1}(\mathbf{x})^{(1-\omega)} \overset{1}{D}_{k+1|k+1}(\mathbf{x})^{\omega} d\mathbf{x} \quad (9.156)$$

注意到式 (9.150) 是一个等式, 不是比例式。因此, 与独立跟踪源多目标 PHD 滤波性能类似, 式 (9.155) 无法简化为单目标指数混合 (XM) 融合公式, 在目标数量较小时, 其融合性能也不会很好。

对式 (9.150) 中的指数权值的优选问题, 与上一小节基于 CPHD 滤波的 XM 融合一样, 涉及指数权重  $\omega$  的优选式 (9.145) 的计算问题。一种解决方法是将 Chernoff 信息推广到 PHD 滤波中:

$$C(\overset{0}{D}_{k+1|k+1}; \overset{1}{D}_{k+1|k+1}) = \sup_{0 \leq \omega \leq 1} (K_{\omega} - \overset{\omega}{N}_{k+1|k+1}) \quad (9.157)$$

式中,

$$K_{\omega} = (1-\omega)\overset{0}{N}_{k+1|k+1} + \omega\overset{1}{N}_{k+1|k+1} \quad (9.158)$$

在实际应用中, 将 Chernoff 信息定义式 (9.35) 应用于服从泊松过程的多目标分布  $\overset{0}{f}_{k+1|k+1}(X)$  和  $\overset{1}{f}_{k+1|k+1}(X)$ , 可得:

$$C(\overset{0}{D}_{k+1|k+1}; \overset{1}{D}_{k+1|k+1}) = \sup_{0 \leq \omega \leq 1} \left( -\ln \int \overset{0}{f}_{k+1|k+1}(X)^{(1-\omega)} \overset{1}{f}_{k+1|k+1}(X)^{\omega} \delta X \right) \quad (9.159)$$

$$= \sup_{0 \leq \omega \leq 1} \left( -\ln \int \left( e^{\overset{0}{N}_{k+1|k+1}} D_{k+1|k+1}^{X^0} \right)^{(1-\omega)} \left( e^{\overset{1}{N}_{k+1|k+1}} D_{k+1|k+1}^{X^1} \right)^{\omega} \delta X \right) \quad (9.160)$$

$$= \sup_{0 \leq \omega \leq 1} \left( K_{\omega} - \ln \int \left( \overset{0}{D}_{k+1|k+1}^{(1-\omega)} \overset{1}{D}_{k+1|k+1}^{\omega} \right)^X \delta X \right) \quad (9.161)$$

于是, 按照式 (9.58) 定义的服从泊松过程的分布, 可知:

$$\int \left( \overset{0}{D}_{k+1|k+1}^{(1-\omega)} \overset{1}{D}_{k+1|k+1}^{\omega} \right)^X \delta X = e^{\overset{\omega}{N}_{k+1|k+1}} \quad (9.162)$$

其中,

$$\overset{\omega}{N}_{k+1|k+1} = \int \overset{0}{D}_{k+1|k+1}(\mathbf{x})^{(1-\omega)} \overset{1}{D}_{k+1|k+1}(\mathbf{x})^{\omega} d\mathbf{x} \quad (9.163)$$

因此,

$$C(\overset{0}{D}_{k+1|k+1}; \overset{1}{D}_{k+1|k+1}) = \sup_{0 \leq \omega \leq 1} \left( K_{\omega} - \ln e^{\overset{\omega}{N}_{k+1|k+1}} \right) \quad (9.164)$$

$$= \sup_{0 \leq \omega \leq 1} \left( K_{\omega} - \overset{\omega}{N}_{k+1|k+1} \right) \quad (9.165)$$

这就得到了将  $\overset{0}{D}_{k+1|k+1}$  和  $\overset{1}{D}_{k+1|k+1}$  的 Chernoff 信息推广到 PHD 滤波的公式 (9.157), 其中如式 (9.163) 所示的  $\overset{\omega}{N}_{k+1|k+1}$  是与权值  $\omega$  对应的期望目标数, 而式 (9.158) 所示的  $K_{\omega}$  是两跟踪源的加权平均目标数。由此可知, 至少在原理上, 式 (9.157) 是可计算的, 于是可以选择:

$$\overset{\text{XM}}{D}_{k+1|k+1}(x) = \overset{\hat{\omega}}{D}_{k+1|k+1}(x) \quad (9.166)$$

其中,

$$\hat{\omega} = \arg \sup_{0 \leq \omega \leq 1} \left( K_{\omega} - \overset{\omega}{N}_{k+1|k+1} \right) \quad (9.167)$$

一个例子是, 假设两跟踪源的期望目标数都与融合的期望目标数相同:

$\overset{0}{N}_{k+1|k+1} = \overset{1}{N}_{k+1|k+1} = N_{k+1|k+1}$ , 此时,  $K_{\omega} = N_{k+1|k+1}$  为常数, 于是可以证明:

$$C(\overset{0}{D}_{k+1|k+1}; \overset{1}{D}_{k+1|k+1}) = N_{k+1|k+1} \cdot \sup_{0 \leq \omega \leq 1} (1 - \int s_{k+1|k+1}(\mathbf{x})^{(1-\omega)} \overset{1}{s}_{k+1|k+1}(\mathbf{x})^{\omega} d\mathbf{x}) \quad (9.168)$$

事实上, 此时

$$\begin{aligned} C(\overset{0}{D}_{k+1|k+1}; \overset{1}{D}_{k+1|k+1}) &= \sup_{0 \leq \omega \leq 1} \left( K_{\omega} - \overset{\omega}{N}_{k+1|k+1} \right) \\ &= \sup \left[ N_{k+1|k+1}(\mathbf{x}) - \int \overset{\omega}{D}_{k+1|k+1}(\mathbf{x}) d\mathbf{x} \right] \\ &= \sup \left[ N_{k+1|k+1}(\mathbf{x}) - \int N_{k+1|k+1}(\mathbf{x}) \overset{\omega}{s}_{k+1|k+1}(\mathbf{x}) d\mathbf{x} \right] \\ &= N_{k+1|k+1}(\mathbf{x}) \sup \left[ 1 - \int s_{k+1|k+1}(\mathbf{x})^{(1-\omega)} \overset{1}{s}_{k+1|k+1}(\mathbf{x})^{\omega} d\mathbf{x} \right] \end{aligned}$$

另一个例子是, 若假设两跟踪源多目标局部航迹的空间分布都与融合的目标航迹空间分布相同, 即  $\overset{0}{s}_{k+1|k+1} = \overset{1}{s}_{k+1|k+1} = s_{k+1|k+1}$ , 则可证明:

$$C(\overset{0}{D}_{k+1|k+1}; \overset{1}{D}_{k+1|k+1}) = \sup_{0 \leq \omega \leq 1} \left( (1-\omega) \overset{0}{N}_{k+1|k+1} + \omega \overset{1}{N}_{k+1|k+1} - \overset{0}{N}_{k+1|k+1}^{(1-\omega)} \overset{1}{N}_{k+1|k+1}^{\omega} \right) \quad (9.169)$$

事实上,

$$\begin{aligned} C(\overset{0}{D}_{k+1|k+1}; \overset{1}{D}_{k+1|k+1}) &= \sup_{0 \leq \omega \leq 1} \left( K_{\omega} - \overset{\omega}{N}_{k+1|k+1} \right) \\ &= \sup \left[ (1-\omega) \overset{0}{N}_{k+1|k+1} + \omega \overset{1}{N}_{k+1|k+1} - \int \overset{0}{D}_{k+1|k+1}(\mathbf{x})^{1-\omega} \overset{1}{D}_{k+1|k+1}(\mathbf{x})^{\omega} d\mathbf{x} \right] \\ &= \sup \left[ (1-\omega) \overset{0}{N}_{k+1|k+1} + \omega \overset{1}{N}_{k+1|k+1} - \int \overset{1-\omega}{N}_{k+1|k+1} \overset{1}{N}_{k+1|k+1}^{\omega} \overset{\omega}{s}_{k+1|k+1}(\mathbf{x})^{(1-\omega)} \overset{1}{s}_{k+1|k+1}(\mathbf{x})^{\omega} d\mathbf{x} \right] \\ &= \sup \left[ (1-\omega) \overset{0}{N}_{k+1|k+1} + \omega \overset{1}{N}_{k+1|k+1} - \overset{0}{N}_{k+1|k+1}^{1-\omega} \overset{1}{N}_{k+1|k+1}^{\omega} \int s_{k+1|k+1}(\mathbf{x}) d\mathbf{x} \right] \\ &= \sup \left[ (1-\omega) \overset{0}{N}_{k+1|k+1} + \omega \overset{1}{N}_{k+1|k+1} - \overset{0}{N}_{k+1|k+1}^{1-\omega} \overset{1}{N}_{k+1|k+1}^{\omega} \right] \end{aligned}$$

## 9.6 基于 CPHD 滤波和 PHD 滤波的多目标 T<sup>2</sup>F 实现案例

本节重点研究前面各节所导出的基于 CPHD 和 PHD 滤波的多目标 T<sup>2</sup>F 公式和指数混合 (XM) 融合近似公式在计算上的可实现性。这里考虑了两个通用的融合结构。第一个应用融合结构考虑各跟踪源采用高斯混合 CPHD (GM—CPHD) 滤波或高斯混合 PHD (GM—PHD) 滤波, 并将各自产生的高斯混合 PHD (一阶矩) 传输给 T<sup>2</sup>F 站点。第二个应用融合结构则考虑各跟踪源采用粒子—CPHD 滤波或粒子—PHD 滤波, 并将它们产生的粒子—PHD 传输给 T<sup>2</sup>F 站点。在这两种应用结构中, 影响实际实现的严重障碍是:

- 9.5.1~9.5.3 节中的精确融合公式涉及 PHD (一阶矩) 相除;
- 9.5.4~9.5.5 节中的 XM 融合公式涉及 PHD 分数幂。

### 9.6.1 基于 CPHD/PHD 滤波的多目标 T<sup>2</sup>F 公式实现

本小节考虑 9.5.1 节~9.5.3 节给出的多目标航迹融合公式的计算实现。其中, 包括各跟踪源采用 GM—CPHD 滤波或 GM—PHD 滤波以及各跟踪源采用粒子—CPHD 滤波或粒子—PHD 滤波两种情况的多目标 T<sup>2</sup>F 公式的计算方法。

#### 案例 1: 基于 GM—PHD 滤波的 T<sup>2</sup>F 计算实现

假设每个跟踪源将其产生的多目标 PHD 以高斯混合 (GM) 的形式传送给 T<sup>2</sup>F 站点。所谓高斯混合形式是指传送给 T<sup>2</sup>F 站点的每个跟踪源航迹分布都是一个随机有限集形式:

$$\{(\lambda_1, \mathbf{x}_1, \mathbf{P}_1), \dots, (\lambda_n, \mathbf{x}_n, \mathbf{P}_n)\}$$

这里, 每个三元组  $(\lambda_i, \mathbf{x}_i, \mathbf{P}_i)$  都是一个高斯随机分量, 其中  $\lambda_i$  为第  $i$  个高斯分布的权重,

$\sum_{i=1}^n \lambda_i = 1$ 。这里所谓的高斯混合 (GM) 即指这  $n$  个高斯随机分布的加权平均。

为了使实现方法表述清晰, 我们考虑最简单的基于 CPHD/PHD 滤波 T<sup>2</sup>F 的贝叶斯并联合公式 (9.124):

$$D_{k+1|k+1}(\mathbf{x}) = D_{k+1|k+1}^1(\mathbf{x}) \cdots D_{k+1|k+1}^s(\mathbf{x}) D_{k+1|k}(\mathbf{x})^{1-s} \quad (9.170)$$

该案例具有典型意义。对该案例提出一个可实现的算法, 就能够给出 9.5.1~9.5.3 节中更复杂的多目标 T<sup>2</sup>F 公式的计算方法。将式 (9.170) 重写为

$$D_{k+1|k+1}(\mathbf{x}) = D_{k+1|k+1}^1(\mathbf{x}) \cdots D_{k+1|k+1}^s(\mathbf{x}) D_{k+1|k}(\mathbf{x})^{-s} D_{k+1|k}(\mathbf{x}) \quad (9.171)$$

式中每个跟踪源提供的 PHD 一阶矩  $D_{k+1|k+1}^j(\mathbf{x})$  ( $j=1, 2, \dots, s$ ), 以及 T<sup>2</sup>F 站点得到的融合预测 PHD 一阶矩  $D_{k+1|k}(\mathbf{x})$  都是一个高斯混合三元组。

对式 (9.171) 所示的基于 PHD 滤波的多目标 T<sup>2</sup>F 公式求解的思路是: 采用粒子与高斯混合 (GM) 相结合的方法进行求解, 实现步骤如下:

① 采用标准的 GM — PHD 滤波的合并与剪裁技术, 将乘积  $D_{k+1|k+1}^1(\mathbf{x}) \cdots D_{k+1|k+1}^s(\mathbf{x})$  缩减为一个新的高斯混合 PHD 一阶矩  $D_{k+1|k+1}^{1 \cdots s}(\mathbf{x})$ 。

② 从  $t_{k+1}$  时刻归一化融合预测 PHD 一阶矩  $D_{k+1|k}(\mathbf{x}) / N_{k+1|k}$  中模拟 (蒙特卡洛) 提取一个统计样本 (粒子集合):

$$\mathbf{x}_{k+1|k}^1, \cdots, \mathbf{x}_{k+1|k}^v \sim D_{k+1|k}(\mathbf{x}) / N_{k+1|k} \quad (9.172)$$

③ 用下述狄拉克混合近似表示  $D_{k+1|k}(\mathbf{x})$

$$D_{k+1|k}(\mathbf{x}) = \frac{N_{k+1|k}}{v} \sum_{i=1}^v \delta_{\mathbf{x}_{k+1|k}^i}(\mathbf{x}) \quad (9.173)$$

式中,  $\delta_{\mathbf{x}_{k+1|k}^i}(\mathbf{x}) = \delta(\mathbf{x} - \mathbf{x}_{k+1|k}^i)$  为浓缩于粒子  $\mathbf{x}_{k+1|k}^i$  处的狄拉克函数。

④ 利用式 (9.171) 和式 (9.173) 确定  $D_{k+1|k+1}(\mathbf{x})$  的粒子近似:

$$\tilde{D}_{k+1|k+1}(\mathbf{x}) = \frac{N_{k+1|k}}{v} \sum_{i=1}^v D_{k+1|k+1}^{1 \cdots s}(\mathbf{x}_{k+1|k}^i) D_{k+1|k}(\mathbf{x}_{k+1|k}^i)^{-s} \delta_{\mathbf{x}_{k+1|k}^i}(\mathbf{x}) \quad (9.174)$$

为了使该式能够有效地逼近  $D_{k+1|k+1}(\mathbf{x})$  真值, 在各跟踪源 PHD 的高斯混合  $D_{k+1|k+1}^{1 \cdots s}(\mathbf{x})$  的各高斯分量均值附近必须保持有足够多的粒子。

⑤ 应用粒子重采样技术将式 (9.173) 转换为分布式粒子表示形式:

$$\tilde{D}_{k+1|k+1}(\mathbf{x}) = \frac{\tilde{N}_{k+1|k+1}}{v} \sum_{i=1}^v \delta_{\mathbf{y}_{k+1|k}^i}(\mathbf{x}) \quad (9.175)$$

式中,  $\mathbf{y}_{k+1|k}^i$  ( $i=1, 2, \cdots, v$ ) 是对式 (9.173) 给出的融合预测的狄拉克混合近似表示  $D_{k+1|k}(\mathbf{x})$  进行重采样获得的粒子集合。式 (9.175) 中:

$$\tilde{N}_{k+1|k+1} = N_{k+1|k} \sum_{i=1}^v D_{k+1|k+1}^{1 \cdots s}(\mathbf{x}_{k+1|k}^i) D_{k+1|k}(\mathbf{x}_{k+1|k}^i)^{-s} \quad (9.176)$$

⑥ 采用 EM 算法或某个其他粒子正则化程序, 将  $\tilde{D}_{k+1|k+1}(\mathbf{x})$  近似表示为一个新的高斯混合  $D_{k+1|k+1}^{(1)}(\mathbf{x})$ 。

⑦ 设

$$D_{k+1|k}^{(1)}(\mathbf{x}) = \frac{N_{k+1|k}}{v} \sum_{i=1}^v \delta_{\mathbf{y}_{k+1|k}^i}(\mathbf{x}) \quad (9.177)$$

返回步骤②~⑥, 获得  $D_{k+1|k+1}^{(2)}(\mathbf{x})$ 。

⑧ 若

$$\left\| D_{k+1|k+1}^{(n)}(\mathbf{x}) - D_{k+1|k+1}^{(n+1)}(\mathbf{x}) \right\| \leq D_\sigma \quad (9.178)$$

迭代结束,  $D_{k+1|k+1}^{(n)}(\mathbf{x})$  即为 PHD 的求解结果; 否则, 返回步骤②~⑦继续迭代。

### 案例 2: 基于粒子滤波的 T<sup>2</sup>F 实现

若各跟踪源向 T<sup>2</sup>F 站点传送的是 PHD 的狄拉克粒子混合形式:

$$D_{k+1|k+1}^j(\mathbf{x}) = \frac{N_{k+1|k}^j}{v} \sum_{i=1}^v \delta_{\mathbf{x}_{k+1|k}^i}(\mathbf{x}) \quad j=1,2,\dots,s \quad (9.179)$$

其中,  $\left\{ \mathbf{x}_{k+1|k}^i \right\}_{i=1}^v$  是从  $D_{k+1|k}^j(\mathbf{x}) / N_{k+1|k}^j$  中抽取的粒子集合, 即

$$\mathbf{x}_{k+1|k}^1, \dots, \mathbf{x}_{k+1|k}^v \sim D_{k+1|k}^j(\mathbf{x}) / N_{k+1|k}^j \quad j=1,\dots,s$$

则实现步骤如下:

① 采用(极大期望)EM 算法或某个其他粒子正则化程序, 将各跟踪源传送来的每个狄拉克混合形式的 PHD 近似表示为一个高斯混合形式。

② 利用案例 1 中的迭代步骤①、④、⑤~⑧, 获得基于粒子滤波的 T<sup>2</sup>F 结果。

## 9.6.2 多目标指数混合(XM) T<sup>2</sup>F 近似公式的计算实现

本节考虑 9.5.4 节和 9.5.5 节给出的多目标指数混合 T<sup>2</sup>F 近似公式的计算实现。包括各跟踪源采用 GM—CPHD 滤波或 GM—PHD 滤波以及各跟踪源采用粒子—CPHD 滤波或粒子—PHD 滤波两种情况的两跟踪源多目标 XMT<sup>2</sup>F 公式的计算方法。

### 案例 1: 基于 GM—PHD 滤波的指数混合 T<sup>2</sup>F 公式的计算实现

与 9.6.1 节案例 1 相同, 假设各跟踪源将其产生的多目标 PHD 以高斯混合形式传送给 T<sup>2</sup>F 站点, 考虑最简单的两跟踪源多目标 XM 融合的 PHD 滤波近似公式(9.150):

$$\overset{\omega}{D}_{k+1|k+1}(\mathbf{x}) = \overset{0}{D}_{k+1|k+1}(\mathbf{x})^{(1-\omega)} \overset{1}{D}_{k+1|k+1}(\mathbf{x})^{\omega} \quad (9.180)$$

给出该最简单问题的计算方法作为典型, 以指导 9.5.5 节中更复杂的 XMT<sup>2</sup>F 公式的计算。

首先, 我们注意到 Julier 提出的适应性近似公式<sup>[15]</sup>:

$$\left( \sum_{i=1}^n \mathbf{x}_i \right)^{\omega} \cong \sum_{i=1}^n \mathbf{x}_i^{\omega}, \left( \sum_{i=1}^n \mathbf{x}_i \right)^{1-\omega} \cong \sum_{i=1}^n \mathbf{x}_i^{1-\omega} \quad (9.181)$$

该公式在 XMT<sup>2</sup>F 公式的计算中具有意想不到的应用效果。

按照两跟踪源提供的 GM—PHD 三元组有限集形式  $\left\{ (\overset{0}{\lambda}_i, \overset{0}{\mathbf{x}}_i, \overset{0}{\mathbf{P}}_i) \right\}_{i=1}^v$  和  $\left\{ (\overset{1}{\lambda}_j, \overset{1}{\mathbf{x}}_j, \overset{1}{\mathbf{P}}_j) \right\}_{j=1}^v$ ,

可得:

$$\overset{0}{D}_{k+1|k+1}(\mathbf{x}) = \sum_{i=1}^v \overset{0}{\lambda}_i N_{\overset{0}{\mathbf{P}}_i}(\mathbf{x} - \overset{0}{\mathbf{x}}_i) \quad (9.182)$$

$$\overset{1}{D}_{k+1|k+1}(\mathbf{x}) = \sum_{j=1}^v \overset{1}{\lambda}_j N_{\overset{1}{\mathbf{P}}_j}(\mathbf{x} - \overset{1}{\mathbf{x}}_j) \quad (9.183)$$

于是, 可以证明相应的 XM 融合公式(9.180)成为

$$\left\{ (\overset{0}{\lambda}_i, \overset{0}{\mathbf{x}}_i, \overset{0}{\mathbf{P}}_i) \right\}_{i=1}^v, \left\{ (\overset{1}{\lambda}_j, \overset{1}{\mathbf{x}}_j, \overset{1}{\mathbf{P}}_j) \right\}_{j=1}^v \rightarrow \left\{ (\overset{\omega}{\lambda}_{i,j}, \overset{\omega}{\mathbf{x}}_{i,j}, \overset{\omega}{\mathbf{P}}_{i,j}) \right\}_{i,j} \quad (9.184)$$

这里,

$$\mathbf{P}_{i,j}^{-1} = (1-\omega)\mathbf{P}_i^{-1} + \omega\mathbf{P}_j^{-1} \quad (9.185)$$

$$\mathbf{P}_{i,j}^{-1} \mathbf{x}_{i,j} = (1-\omega)\mathbf{P}_i^{-1} \mathbf{x}_i + \omega\mathbf{P}_j^{-1} \mathbf{x}_j \quad (9.186)$$

$$\lambda_{i,j}^\omega = \frac{\lambda_i^{1-\omega} \lambda_j^\omega}{\sqrt{\omega^M (1-\omega)^M}} N_{\mathbf{P}_i/(1-\omega) + \mathbf{P}_j/\omega}^0 (\mathbf{x}_j - \mathbf{x}_i) \quad (9.187)$$

式(9.187)中,  $M$  是欧氏空间的维数。

事实上, 将式(9.182)、式(9.183)代入式(9.180), 再利用近似式(9.181)可得到:

$$\begin{aligned} \bar{D}_{k+1|k+1}^\omega(\mathbf{x}) &= \bar{D}_{k+1|k+1}^0(\mathbf{x})^{(1-\omega)} \bar{D}_{k+1|k+1}^1(\mathbf{x})^\omega \\ &\cong \left( \sum_{i=1}^v \lambda_i^{1-\omega} N_{\mathbf{P}_i}^0(\mathbf{x} - \mathbf{x}_i)^{1-\omega} \right) \left( \sum_{j=1}^v \lambda_j^\omega N_{\mathbf{P}_j}^1(\mathbf{x} - \mathbf{x}_j)^\omega \right) \end{aligned} \quad (9.188)$$

$$= \sum_{i=1}^v \sum_{j=1}^v \lambda_i^{1-\omega} \lambda_j^\omega N_{\mathbf{P}_i}^0(\mathbf{x} - \mathbf{x}_i)^{1-\omega} N_{\mathbf{P}_j}^1(\mathbf{x} - \mathbf{x}_j)^\omega \quad (9.189)$$

$$= \sum_{i=1}^v \sum_{j=1}^v \lambda_i^{1-\omega} \lambda_j^\omega \sqrt{\frac{\det(2\pi \mathbf{P}_i/(1-\omega)) \det(2\pi \mathbf{P}_j/\omega)}{\det(2\pi \mathbf{P}_i) \det(2\pi \mathbf{P}_j)}} N_{\mathbf{P}_i/(1-\omega)}^0(\mathbf{x} - \mathbf{x}_i) N_{\mathbf{P}_j/\omega}^1(\mathbf{x} - \mathbf{x}_j) \quad (9.190)$$

$$= \sum_{i=1}^v \sum_{j=1}^v \frac{\lambda_i^{1-\omega} \lambda_j^\omega}{\sqrt{\omega^N (1-\omega)^N}} N_{\mathbf{P}_i/(1-\omega) + \mathbf{P}_j/\omega}^0(\mathbf{x}_j - \mathbf{x}_i) N_{\mathbf{P}_{i,j}}^\omega(\mathbf{x} - \mathbf{x}_{i,j}) = \left\{ (\lambda_{i,j}^\omega, \mathbf{x}_{i,j}, \mathbf{P}_{i,j}) \right\}_{i,j} \quad (9.191)$$

式中, 融合的三元组有限集  $\left\{ (\lambda_{i,j}^\omega, \mathbf{x}_{i,j}, \mathbf{P}_{i,j}) \right\} \quad \left( i=1, \dots, v; j=1, \dots, v \right)$  中各元素可分别由式(9.185)~式(9.187)得到。

对于指数权值  $\omega$  的优选问题, 我们注意到, 在获得式(9.185)~式(9.191)之后, 即可得到:

$$\bar{N}_{k+1|k+1}^\omega = \int \bar{D}_{k+1|k+1}^\omega(\mathbf{x}) d\mathbf{x} \quad (9.192)$$

$$= \sum_{i=1}^v \sum_{j=1}^v \frac{\lambda_i^{1-\omega} \lambda_j^\omega}{\sqrt{\omega^N (1-\omega)^N}} N_{\mathbf{P}_i/(1-\omega) + \mathbf{P}_j/\omega}^0(\mathbf{x}_j - \mathbf{x}_i) \quad (9.193)$$

然后, 从9.5.5节对两跟踪源局部多目标航迹 PHD(一阶矩)的 Chernoff 信息定义式(9.157):

$$C(\bar{D}_{k+1|k+1}^0; \bar{D}_{k+1|k+1}^1) = \sup_{0 \leq \omega \leq 1} (K_\omega - \bar{N}_{k+1|k+1}^\omega) \quad (9.194)$$

可知 Chernoff 信息近似于  $K_\omega - \bar{N}_{k+1|k+1}^\omega$  关于  $\omega$  的上确界, 其中  $K_\omega$  是以  $\omega$  和  $1-\omega$  加权的平均目标数量:

$$K_\omega = (1-\omega)\bar{N}_{k+1|k+1}^0 + \omega\bar{N}_{k+1|k+1}^1 \quad (9.195)$$

我们知道, Chernoff 信息能够定量表示  $\bar{D}_{k+1|k+1}^\omega(\mathbf{x})$ , 因此, 优化的指数权值  $\hat{\omega}$  可以选择为

$$\hat{\omega} = \arg \sup_{\omega} (K_{\omega} - \bar{N}_{k+1|k+1}) \quad (9.196)$$

$$= \arg \sup_{\omega} \sum_{i=1}^0 \sum_{j=1}^1 \left( \frac{(1-\omega) \lambda_i^0}{\nu^0} + \frac{\omega \lambda_i^1}{\nu^1} - \frac{\lambda_i^{1-\omega} \lambda_j^{\omega}}{\sqrt{\omega^N (1-\omega)^N}} N_{\mathbf{P}_i / (1-\omega) + \mathbf{P}_j / \omega}^0 (\mathbf{x}_j - \mathbf{x}_i) \right) \quad (9.197)$$

### 案例 2：基于粒子滤波的 XM—PHD 航迹融合公式的计算实现

与 9.6.1 节案例 2 类似，此时两跟踪源向 T<sup>2</sup>F 站点传送的是 PHD 的狄拉克粒子混合形式：

$$\bar{D}_{k+1|k+1}^0(\mathbf{x}) = \frac{N_{k+1|k}}{\nu^0} \sum_{i=1}^0 \delta_{\mathbf{x}_{k+1|k}^i}(\mathbf{x}) \quad (9.198)$$

$$\bar{D}_{k+1|k+1}^1(\mathbf{x}) = \frac{N_{k+1|k}}{\nu^1} \sum_{j=1}^1 \delta_{\mathbf{x}_{k+1|k}^j}(\mathbf{x}) \quad (9.199)$$

其中，

$$\begin{aligned} \mathbf{x}_{k+1|k}^1, \dots, \mathbf{x}_{k+1|k}^{\nu^0} &\sim \bar{D}_{k+1|k}^0(\mathbf{x}) / N_{k+1|k}^0 \\ \mathbf{x}_{k+1|k}^1, \dots, \mathbf{x}_{k+1|k}^{\nu^1} &\sim \bar{D}_{k+1|k}^1(\mathbf{x}) / N_{k+1|k}^1 \end{aligned}$$

于是，可采用（极大期望）EM 算法或某个其他粒子正则化程序，将  $\bar{D}_{k+1|k+1}^0(\mathbf{x})$  和  $\bar{D}_{k+1|k+1}^1(\mathbf{x})$  近似为高斯混合三元组有限集  $\left\{ (\lambda_i^0, \mathbf{x}_i^0, \mathbf{P}_i^0) \right\}_{i=1}^{\nu^0}$ ,  $\left\{ (\lambda_j^1, \mathbf{x}_j^1, \mathbf{P}_j^1) \right\}_{j=1}^{\nu^1}$ ，然后按案例 1 给出的方法进行计算。

## 9.7 本章小结

本章之所以称为分布式信息融合发展的理论基础，是因为本章的内容包括了近 30 年来集中式信息融合的某些研究成果向分布式信息融合领域的扩展和应用。本章第 2 节所描述的单目标贝叶斯滤波既是独立数据源环境下的集中式信息融合的理论基础，也是非独立（相关）环境下分布式信息融合（特别是分布式 T<sup>2</sup>F）的理论基础。本章描述了针对多数据源之间的相关性问题的几个启发性（尝试性）方法，包括两个典型方法：协方差交集（CI）航迹融合和指数混合（XM）融合方法，这两个方法是单目标多源融合定位、识别与跟踪中已广泛应用且行之有效的方法，将这两个方法从而自然地扩展到多目标，成为多源多目标分布式融合的理论基础。

在面对多传感器多目标跟踪问题时，本章没有采取传统的关联—融合模式，尽管该模式已在应用上被证明是成功的。由于数据或航迹关联存在众多难以解决的不确定性问题，因此本章将随机有限集作为多目标分布式融合发展的理论基础之一，包括建立多传感器多目标递推贝叶斯滤波的随机集模型和方法，通过泛函的微分和积分运算解决随机分布的多目标（状态和数量/基数）估计问题。本章给出了基于随机有限集理论的概率假设密度（PHD）

滤波和基函数化概率假设密度 (CPHD) 滤波模型, 以及它们作为独立跟踪源和相关跟踪源的  $T^2F$ 、指数混合  $T^2F$  的近似方法和几个实现案例。然而, 必须指出的是, 本章的 PHD 滤波和 CPHD 滤波仅限于泊松分布过程和独立同分布聚类两个随机有限子集, 在模型计算上尚存在不少需要解决的问题, 特别是无法在根本上解决数据或航迹关联中的不确定性, 这是多目标跟踪中无法回避的问题。9.3.5 节描述了基于随机有限集的滤波技术的应用现状。目前, 随机有限集仅是多目标跟踪的分布式融合问题研究和发展的一个方向, 将其作为分布式融合的理论基础还只是部分人的建议, 尚有待进一步研究、发展和完善。

## 参考文献

- [1] O E Drummond. On track and tracklet fusion filtering. in O.E. Drummond, Signal and Data Processing of Small Targets 2002, SPIE Proceedings, Bellingham, WA, 2002, Vol. 4728, 176–195.
- [2] C Y Chong, S Mori, K C Chang. Distributed multitarget multisensor tracking. in Y. Bar-Shalom, Multitarget-Multisensor Tracking: Advanced Applications, Chapter 8, Artech House, London, U K, 1990; Re-published as Multitarget-Multisensor Tracking: Advances and Applications, YBS, Storrs, CT, 1996, Vol. I.
- [3] R Mahler. Optimal/robust distributed data fusion: A unified approach. in I. Kadar, Signal Processing, Sensor Fusion, and Target Recognition IX, SPIE Proceedings, Orlando, FL, 2000, Vol. 4052, 128–138.
- [4] D Clark, S Julier, R Mahler, et al. Robust multi-object sensor fusion with unknown correlations. Proceedings of the Conference on Sensor Signal Processing for Defence 2010 (SSPD2010), Imperial College, London, U K, September, 2010, 29–30.
- [5] M Uney, D Clark, S Julier. Information measures in distributed multitarget tracking. Proceedings of the 14th International Conference on Information Fusion, Chicago, IL, July 5–8, 2011.
- [6] M Uney, S Julier, D Clark, et al Monte Carlo realisation of a distributed multi-object fusion algorithm. Proceedings of the Conference on Sensor Signal Processing for Defence 2010 (SSPD2010), Imperial College, London, U K, September, 2010, 29–30.
- [7] R Mahler. Statistical Multisource-Multitarget Information Fusion. Artech House, Norwood, MA, 2007.
- [8] J K Uhlmann. General data fusion for estimates with unknown cross covariances. SPIE Proceedings, 1996, 2755, 536–547.
- [9] S Julie, J Uhlmann. A non-divergent estimation algorithm in the presence of unknown correlations. Proceedings of the IEEE American Control Conference, Albuquerque, NM, June 4–6, 1997 Vol. 4, 2369–2373.
- [10] S Julier, J Uhlmann. General decentralized data fusion with covariance intersection. Handbook of Multisensor Data Fusion (2nd edn), CRC Press, Boca Raton, FL, 2008, Chapter 14, 319–343.
- [11] D. Fränken and A. Hüpper, Improved fast covariance intersection for distributed data fusion, Proceedings of the 8th International Conference on Information Fusion, Philadelphia, PA, July 25–28, 2005, 154–160.
- [12] M Hurley. An information-theoretic justification for covariance intersection and its generalization.



- Proceedings of the 5th International Conference on Information Fusion, Annapolis, MD, July 7–11, 2002.
- [13] T Heskes. Selecting weighting factors in logarithm opinion pools. *Advances in Neural Information Processing Systems*, 1998, 10, 266–272.
- [14] S Julier, T Bailey, J Uhlmann. Using exponential mixture models for suboptimal distributed data fusion. *Proceedings of the 2006 IEEE Nonlinear Signal Processing Workshop*, Birmingham, U.K., September 13–15, 2006.
- [15] J Julier. An empirical study into the use of Chernoff information for robust, distributed fusion of Gaussian mixture models. *Proceedings of the 9th International Conference on Information Fusion*, Florence, Italy, July 10–13, 2006.
- [16] W Farrell III, C Ganesh. Generalized Chernoff fusion approximation for practical distributed data fusion. *Proceedings of the 12th International Conference on Information Fusion*, Seattle, WA, July 6–9, 2009, 555–562.
- [17] S Julier. Fusion without independence. *Proceedings of the 2008 IET Seminar on Tracking and Data Fusion: Algorithms and Applications*, Birmingham, U K, April 15–16, 2008, 1–5.
- [18] I Csiszár. I-divergence geometry of probability distributions and minimization problems. *Annals of Probability*, 1975, 3(1), 146–158.
- [19] I Csiszár. Information-type measures of difference of probability distributions and indirect observations. *Studia Scientiarum Mathematicarum Hungarica*, 1967, 2, 299–318.
- [20] T Zajic, R Mahler. Practical information-based data fusion performance evaluation. *SPIE Proceedings*, 1999, 3720, 92–103.
- [21] R Mahler. Random set theory for target tracking and identification. *Handbook of Multisensor Data Fusion* (2nd edn), CRC Press, Boca Raton, FL, 2008, Chapter 16, 369–410.
- [22] R Mahler. Statistics 101 for multisensor, multitarget data fusion. *IEEE Aerospace and Electronics Systems Magazine*, Part 2: Tutorials, 2004, 19(1), 53–64.
- [23] R Mahler. PHD filters of higher order in target number. *IEEE Transactions on Aerospace and Electronic Systems*, 2007, 43(4), 1523–1543.
- [24] B N Vo, B T Vo, N Pham. Bayesian multi-object estimation from image observations. *Proceedings of the 12th International Conference on Information Fusion*, Seattle, WA, July 6–9, 2009.
- [25] B T Vo, B N Vo, A Cantoni. The cardinality balanced multi-target multi-Bernoulli filter and its implementations. *IEEE Transactions on Aerospace and Electronic Systems*, 2009, 57(2), 409–423.
- [26] J Mullane, B N Vo, M Adams, et al. A random set approach to Bayesian SLAM. *IEEE Trans Robotics and Automation*, 2011, 27(2), 268–282.
- [27] J Mullane, B N Vo, M Adams, et al. *Random Finite Sets in Robotic Map Building and SLAM*. Springer, 2011.
- [28] C S Lee, D Clark, J Salvi. SLAM with single cluster PHD filters. *Proceedings of the 2012 IEEE International Conference on Robotics and Automation (ICRA2012)*, St Paul, MN, 2012.

- [29] R Mahler. CPHD and PHD filters for unknown backgrounds I: Dynamic data clustering. *Sensors and Systems for Space Applications III*, SPIE Proceedings, 2009, Vol. 7330.
- [30] R Mahler. CPHD and PHD filters for unknown backgrounds II: Multitarget filtering in dynamic clutter. *Sensors and Systems for Space Applications III*, SPIE Proceedings, 2009, Vol. 7330.
- [31] R Mahler, A El-Fallah. CPHD and PHD filters for unknown backgrounds III: Tractable multitarget filtering in dynamic clutter. *Signals and Data Processing of Small Targets 2010*, SPIE Proceedings, 2010, Vol. 7698.
- [32] R Mahler A El-Fallah. CPHD filtering with unknown probability of detection. *Signal Processing, Sensor Fusion, and Target Recognition XIX*, SPIE Proceedings, 2010, Vol. 7697.
- [33] R Mahler, B T Vo, B N Vo. CPHD filtering with unknown clutter rate and detection profile. *Proceedings of the 14th International Conference on Information Fusion*, Chicago, IL, July 5–8, 2011.
- [34] R Mahler, B T Vo, B N Vo. CPHD filtering with unknown clutter rate and detection profile. *IEEE Transactions on Signal Processing*, 2011, 59(6), 3497–3513.
- [35] B T Vo, B N Vo, R Hoseinnezhad, et al. Multi-Bernoulli filtering with unknown clutter intensity and sensor field-of-view. *Proceedings of the 2011 IEEE Conference on Information Sciences and Systems*, Baltimore, MD, March 23–25, 2011.
- [36] B T Vo, B N Vo, R Hoseinnezhad, et al. Multi-Bernoulli filtering with unknown clutter intensity and sensor field-of-view. *Proceedings of the 45th Annual Conference on Information Sciences and Systems (CICS2011)*, Johns Hopkins University, Baltimore, MD, March 23–25, 2011.
- [37] B T Vo, B N Vo, R Hoseinnezhad, et al. Multi-Bernoulli filtering with unknown clutter intensity and sensor field-of-view. *IEEE Transactions on Aerospace and Electronic Systems*, 2011.
- [38] S Nagappa, D Clark. On the ordering of the sensors in the iterated-corrector probability hypothesis density (PHD) filter, *Signal Processing, Sensor Fusion, and Target Recognition XX*, SPIE Proc, Orlando, FL, April 26–28, 2011, Vol. 8050.
- [39] R Mahler. Approximate multisensor CPHD and PHD filters. *Proceedings of the 13th International Conference on Information Fusion*, Edinburgh, Scotland, July 26–29, 2010.
- [40] S Nagappa, D Clark, R Mahler. Incorporating track uncertainty into the OSPA metric. *Proceedings of the 14th International Conference on Information Fusion*, Chicago, IL, July 5–8, 2011.
- [41] R Mahler, A El-Fallah. Unified Bayesian registration and tracking. *Signal Processing, Sensor Fusion, and Target Recognition XX*, SPIE Proceedings, Orlando, FL, April 26–28, 2011, Vol. 8050.
- [42] R Ristić, D Clark. Particle filter for joint estimation of multi-object dynamic state and multi-sensor bias. *Proceedings of the 37th IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP2012)*, Kyoto, Japan, March 25–30, 2012.
- [43] R Mahler. Multitarget filtering via first-order multitarget moments. *IEEE Transactions on Aerospace and Electronics Systems*, 2003, 39(4), 1152–1178.
- [44] R Hoseinnezhad, B N Vo, D Suter, et al. Multi-object filtering from image sequence without detection.

- Proceedings of the 2010 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Dallas, TX, March 14–19, 2010.
- [45] D Clark, B N Vo. Convergence analysis of the Gaussian mixture PHD filter. *IEEE Transactions on Signal Processing*, 2007, 55(4), 1204–1212.
- [46] K Panta, D Clark, B N Vo. Data association and track management for the Gaussian mixture probability hypothesis density filter. *IEEE Transactions on Aerospace and Electronic Systems*, 45(3), 1003–1016, 2009.
- [47] B N Vo, W K Ma. The Gaussian mixture probability hypothesis density filter. *IEEE Transactions on Signal Processing*, 2006, 54(11), 4091–4104.
- [48] 赵宗贵, 刁联旺, 李君灵, 等. 信息融合工程实践. 北京: 国防工业出版社, 2015.
- [49] 赵宗贵, 熊朝华. 信息融合概念、方法与应用. 北京: 国防工业出版社, 2012.

# 第 10 章 分布式环境中的威胁估计

## 10.1 威胁估计基本概念

### 10.1.1 威胁与威胁对象

#### 1. 威胁概念与内涵

威胁是指用武力或权势进行的胁迫行为。在军事领域中，威胁主要是指动用军事力量打击、攻击、占领或控制防卫对象。威胁可能来自单一的实体或群体，可以通过威胁事件和威胁行动实现对防卫对象的威胁。威胁是意图、能力和时机的综合体。其中，意图是指威胁的目的，即想要威胁的对象及对其造成的伤害；能力是指威胁实体实现其意图所能够动用的力量和资源；时机是指威胁行动得以成功实施需要具备的先决条件，包括时间、空间和威胁对象的脆弱点等<sup>[1,2]</sup>。

#### 2. 威胁对象内涵及其拓展

威胁对象主要由功能效用、组成分布、结构特征、属性分类、要害部位、定位精度、电磁特征、防御设施、地理环境、天候气象等要素构成。美军认为，“对象是一个地区、一座综合性建筑物、一个设施、一支部队、一种装备、一种作战能力、一种功能或某种行为”<sup>[2]</sup>。随着信息化作战概念的深入发展，对象已经从实体向非实体跨越，体现了从物质域向非物质域的演变，甚至把人的认知能力、心理状况都纳入到威胁对象之中，如心理战、法律战和舆论战等，从而使对象的内涵正在从客观向主观领域拓展。

### 10.1.2 威胁估计概念

#### 1. 威胁估计与态势估计

在 JDL 信息融合顶层模型中，威胁估计处于信息融合的第 3 级，与第 2 级态势估计一起属于高级信息融合范畴。JDL 信息融合顶层模型将威胁估计称为影响估计，即基于共用作战态势预测未来战场态势所产生的影响。其中，对我方不利的影响被称为威胁<sup>[3]</sup>。因此，威胁估计与态势估计密不可分。威胁估计实际上是预测态势的效用估计，故有时被合称为态势与威胁估计（STA）<sup>[1]</sup>，如图 10.1 所示。

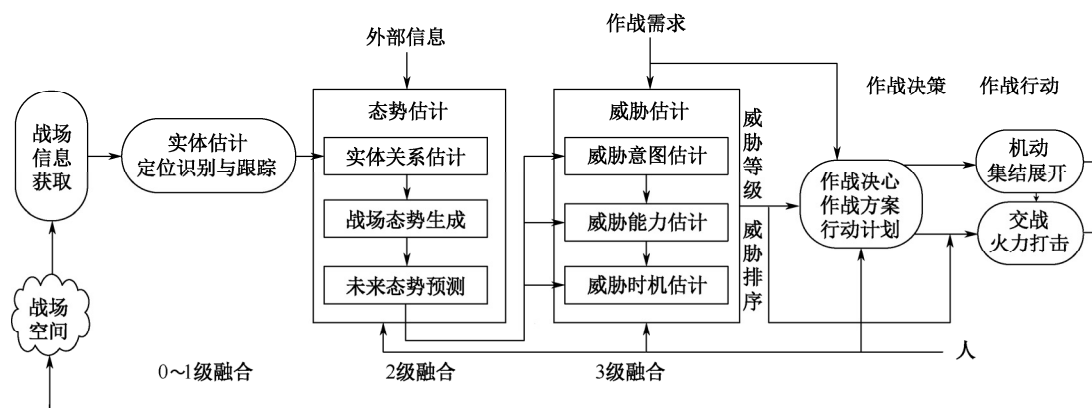


图 10.1 信息融合中的 STA 及其作战应用

## 2. 威胁估计与战场“场景”

我们知道,  $k$  时刻战场态势  $S_t(k)$  由多个战场对象及其关系构成, 即  $S_t(k) = \bigcup_{i=1}^m s_i(t)$ 。由于态势定义为描述战斗或战术行动的一个战场局部现实结构, 故可被称为局部态势, 而多个局部态势及其之间的关系将构成整个战场的全局“场景”。某一时刻  $k$  的场景  $S_{C_1}(k)$  被称为单一场景, 由局部态势在空间上扩展产生, 即  $S_{C_1}(k) = \bigcup_{j=1}^n s_{t_j}(k)$ 。场景变化产生于场景中各局部态势之间的相互作用。单一场景  $S_{C_1}(k)$  又可在时间上扩展为复合场景  $S_{C_2}(k) = \sum_{q=k+1}^{k+z(k)} S_{C_1}(q)$ 。该复合场景  $S_{C_2}(k)$  由  $z(k)$  个单一预测场景及其关系构成。

上述概念及关系如图 10.2 所示。

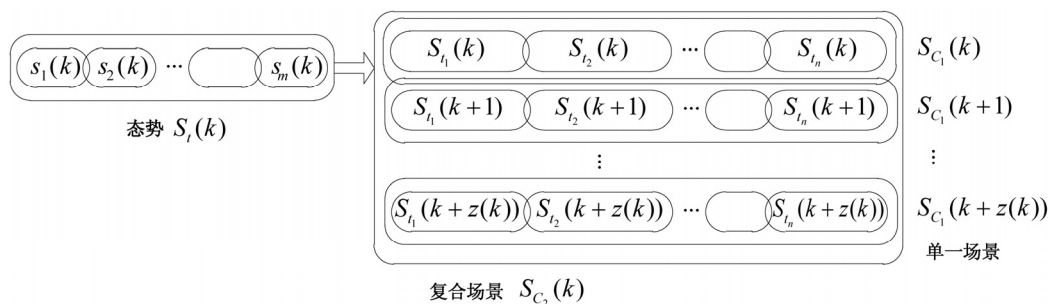


图 10.2 战场态势、单一场景、复合场景及其之间的关系

由上述分析和图 10.2 给出的关系结构能够看出：

- 某时刻战场对象（实体）及其关系对战场态势状态产生影响；
- 某一场景中的诸态势状态及其关系对场景状态产生影响；
- 一个作战阶段的多时节复合场景中诸单一场景及其之间的关系对该作战阶段过程和效果产生影响。

于是, 我们得到如下结论：

影响或威胁是随态势在空间上向场景扩展, 在时间上向多作战阶段或时节复合场景扩展出现的。因此, 态势的作用和影响产生于场景中诸态势之间的关系。由于威胁是指对我方意

图和行动不利的作用和影响,故体现态势效用的威胁估计又可被称为场景中诸态势的时空关系估计。

### 10.1.3 威胁估计的特征与内涵

#### 1. 威胁估计的特征

- 时间特征:威胁是预测态势对未来战场产生的影响,威胁估计是对未来战场态势产生的效用进行估计,也可以说是态势估计向未来的扩展,即建立未来战场实体、事件之间的关系及估计可能产生的事件、后果及代价。
- 认知特征:威胁估计是通过指挥员对预测态势的认知实现的,与人对威胁意图(第一要素)的理解并将其与防卫方作战任务耦合的准确认知有关。
- 作战特征:态势估计跨越感知域和作战域,是基于作战条令/条例建立感知域中实体之间的关系,可生成战场态势视图;威胁估计直接具有作战特征,其威胁意图估计、能力估计和时机估计是指挥员和军事专家对预测态势的深入理解和分析获得的,是生成共用作战图的基础。
- 定量特征:与态势估计以定性分析为主不同,威胁估计能够给出一定的定量估计结果,如来袭目标的威胁等级、多目标威胁排序,以及通过某些特定威胁因素的计算确定目标威胁值或威胁度等。定量特征具有可回溯性,能提高估计结果的可信性。
- 效用特征:威胁估计在网络中心战(NCW)的价值链中,对预测态势理解环节和作战方案判断环节具有举足轻重的作用,是产生知识优势和决策优势的关键,并为获得协同行动优势和效能优势提供有力支撑。
- 不确定性特征:千变万化的战场态势和态势感知误差使态势预测存在众多随机性和模糊性;囿于指挥员和军事专家知识的经验,又使威胁估计面临认知的复杂性和多义性。这些不确定性往往使人们对威胁估计的可信情况产生质疑。采用最新的不确定性处理技术和人一代理集合体(HAC)的感知融合方法来应对威胁估计中的不确定性是当前普遍采用的技术途径。

#### 2. 威胁估计的内涵

威胁估计主要包含威胁意图估计、威胁能力估计和威胁时机估计,对这 3 项内容的展开和相关扩展产生如下威胁估计内涵<sup>[4]</sup>:

- 预测威胁方未来可能采取的行动,包括可能采取的所有行动,对防卫方有害的威胁行动(含威胁类型和级别),最有可能采取的威胁行动。
- 预测未来威胁方的意图,包括确定防卫方所有可能的被威胁对象,识别和判断防卫方资源可能受到的所有主要威胁(类型和级别),估计和预测未来威胁行动的可能执行者,预测威胁执行者的意图(可能威胁的对象),确定防卫方防卫力量与威胁力量在兵力、武器、装备状态与能力对比。
- 估计威胁方的威胁能力,包括兵力编成和强度,兵力分布与协同能力,能够采取行

动的类型、规模和持续时间，与威胁对象防卫力量对比的优势。

- 识别和判断威胁方采取威胁行动的时机，包括可能的威胁行动类型及对威胁执行者可能的有利行动时机，防卫对象的薄弱环节和脆弱点，威胁对象的可接近性，可能的交战时间（展开时间、突防时间、遭遇时间）。
- 估计和预测威胁行动可能产生的影响，包括基于双方对抗措施的兵力对抗行动分析，基于双方对抗兵力配比确定最小代价的交战行动，确定防卫方在对抗行动中的优先打击（拦截）目标，可能出现的对抗事件预测，可能的威胁事件结果预测（包括效果和代价）。

#### 10.1.4 威胁估计要素及其层次结构

##### 1. 威胁估计要素与分类

由于威胁估计是确定预测态势对未来战场和作战行动产生的影响，因此威胁估计要素与预测态势要素基本相同<sup>[5]</sup>，只是增加了当前态势中尚不存在但未来可能出现的某些态势要素，如威胁对抗事件及其产生的影响等。威胁估计要素主要是指威胁估计所依赖和产生的诸多因素，与威胁程度估计过程密切相关。指挥员估计目标威胁程度主要通过依次估计各威胁要素实现。威胁估计要素按层次分为：

- 实体要素，战场存在的实体，包含兵力、武器装备和环境状态要素，相当于一级态势；
- 关系要素，基于作战条令/条例产生的战场实体及其与环境要素、外部因素之间的关系，相当于二、三级态势要素；
- 知识要素，从实体要素和关系要素中提取出来的威胁状态要素，包括威胁意图、威胁能力和威胁时机等要素；
- 事件要素，未来可能出现的战场事件及其产生的影响或作用要素，战场事件包括事件类型、可能采取的行动样式及威胁状态要素出现重大变化等事件。

##### 2. 威胁估计要素层次结构

威胁估计要素由上而下按层次展开的结构如图 10.3 所示。

##### 3. 陆、海、空域目标的主要威胁要素与特征

在图 10.3 给出的威胁估计要素层次结构中所列出的各层次目标威胁要素对于地面、空中和海上目标在内涵上有一定的差别，或者说，这 3 个域中的目标威胁估计要素分别是如图 10.3 所示要素的子集。各子集基本内涵如下：

对空中目标进行威胁程度估计时，防空指挥员需要考虑的目标威胁因素主要有目标携带的辐射源特征（主要是指雷达系统类型、通信频率、电子对抗频段等），目标飞行高度、方向（接近或远离我方平台）、速度、航向、类型和型号，相对于我方平台的距离、威胁目标的协同行动（编队、攻击等），IFF 应答模式（用于判断己方、中立和友方的属性），目标（武器平台）的火力打击范围、航路捷径、空间位置（位于海洋上空还是陆地上空），友军支援状况，目标机动状态、是否装备作战指挥系统、是否携带导弹及目标的可发现程度等。

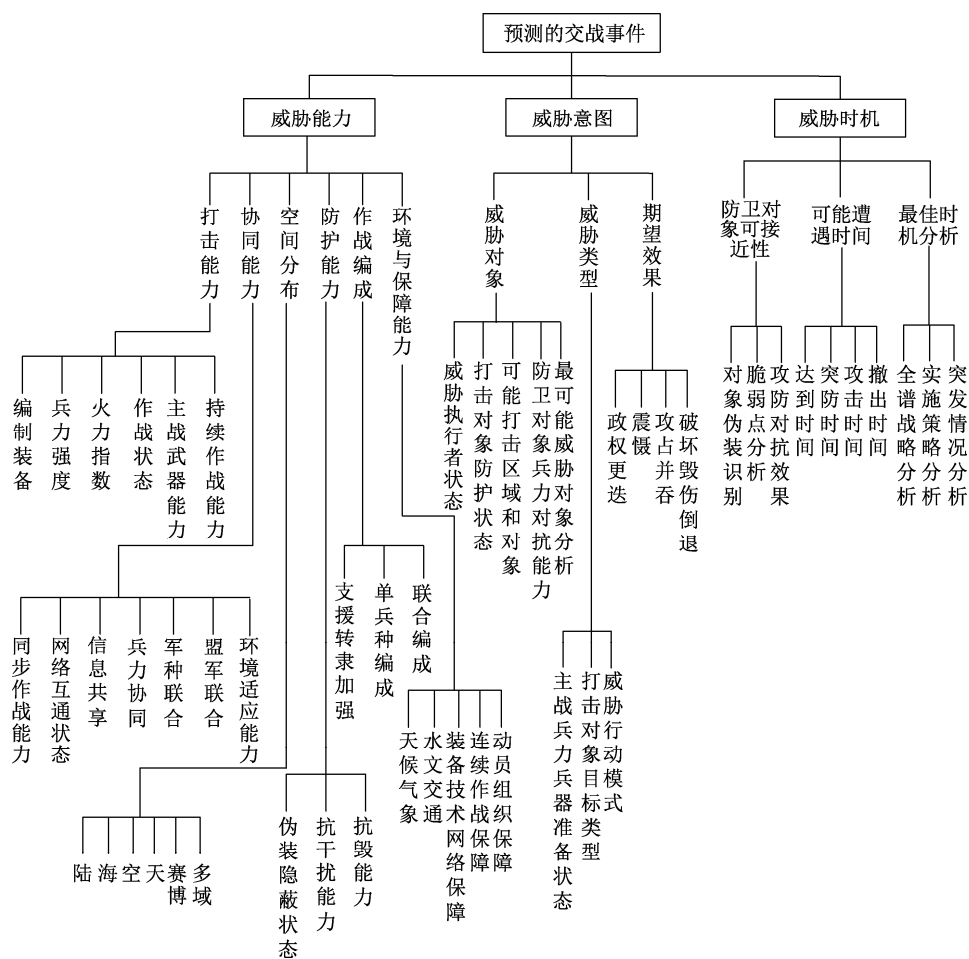


图 10.3 威胁估计要素由上而下按层次展开的结构

对海上目标进行威胁程度估计时,指挥员需要考虑的威胁因素主要有舰船装载物(飞机、武器,包括人员)、协同行动、航路捷径、航行的目的地、所载的辐射源、舰船的航向(远离还是接近我方平台)、编队舰船的数量、支援的舰船或巡逻飞机,敌我方舰船的相对距离,舰船最近的机动情况,敌舰船的航路性质,航行速度或速度变化(加速),目标的通信范围和武器作用范围等。

对陆地地面目标进行威胁估计时,指挥员考虑的威胁因素主要有目标数量、攻击和防卫能力、武器作用距离和发射状态、运动速度和行动路线、目标的海拔高度及目标的类型和射击扇区(火力责任区)等。还有其他一些目标,如辐射源目标的威胁估计要素限于篇幅就不一一讨论了。威胁要素量化处理存在下述特征:

**确定性与不确定性：**使用多源获取的目标威胁要素信息一般需要经过量化处理。信源的可信性、传感器本身的测量误差，及状态和测量数学模型的近似性和时变性可使获取的目标威胁要素含有误差，用均值和方差描述。如果仅仅使用均值进行目标威胁要素量化处理，则忽略了目标威胁要素的不确定性而转化为确定性信息；如果在量化处理中既考虑均值又考虑方差，则目标威胁要素的量化处理是不确定性的。

**静态性与动态性：**在目标威胁要素中，状态类的信息大都是随时间而动态变化的，而属



性类的信息属于静态的,因此在处理目标威胁要素的量化过程中,一定要根据目标威胁要素的自身特点进行量化处理。另外需要注意的就是,根据威胁要素是成本型、效益型及折中型等特点进行量化分析与处理。

一般性与特殊性:在目标威胁要素中,有些要素本身具有多指标特点,如武器作用范围(或有效射程),由于作战平台具有多类功能,其遂行的作战任务是多样的,打击的目标类型不同,其武器作战范围也明显不同。因此,在这些目标威胁要素的归一化处理过程中,不仅要考虑战技指标的一般性,还要结合具体作战应用的特殊性,这样量化处理的结果才具有可靠性和科学性。

### 10.1.5 威胁估计结果的表示方法

目标威胁估计所给出目标威胁程度的表示方法有如下 3 种。

目标威胁的等级。目标威胁等级是根据对目标拦截和打击任务需要,把目标威胁程度划分为若干等级。目前采用的等级划分主要有两类:一类是严重、中等和小三级划分;另一类是严重、较严重、中等、较小和小五级划分方法。在基于定性推理的目标威胁估计方法类,如产生式规则方法中,通常就是目标威胁等级或威胁等级计算模型。由于目标威胁不同等级之间的边界是模糊的,但符合人类思维的特点,因此是目前广为采用的一种方法。

目标威胁估计值。目标威胁估计值是基于定量计算的威胁估计方法普遍采用的表示方法,主要是通过某种数学模型给出综合各种威胁要素的计算结果,然后结合军事应用需求,转换成目标威胁值或基于该威胁值确定目标威胁等级或直接对目标威胁程度进行排序,在基于信息系统的目标威胁估计处理模块中普遍采用这种方式。但由于威胁要素的处理未考虑其取值的不确定性,人们对目标威胁估计计算结果的可信性会产生怀疑,因此增强计算结果的可信度是急需解决的问题。

目标威胁排序。目标威胁排序也是一种相对性目标威胁程度表示方法,是根据战术需要把当前目标按威胁程度大小排序,而不论其隶属的威胁等级或威胁估计值之间的绝对取值大小。在基于定量计算和网络图的目标估计方法类中,通常根据威胁估计的结果对目标威胁程度进行排序,是战术应用中确定目标实施拦截或打击优先级广泛采用的方式。

## 10.2 基于假设评估的威胁估计推理模型

### 10.2.1 威胁估计模型

在图 10.3 给出的威胁估计要素层次结构中,每一层次的要素都可采用模型表示,包括物理模型、数据模型、随机统计模型、静态与动态对象模型及单指标或多指标运筹模型和博弈对抗模型、不确定性推理模型等<sup>[7]</sup>。模型的选择与要素的智能水平有关,如威胁能力中的打击能力要素通常以物理模型和随机统计模型为主,协同能力则以运筹模型为主,战场环境和保障能力要素以数据模型为主,威胁意图和威胁时机主要以多假设运筹和博弈模型为主。

从内涵上讲,威胁估计状态三要素是威胁能力、威胁意图和威胁时机。相应的三类威胁

估计模型如下。

(1) 威胁能力模型, 从 10.1.3 节描述的威胁估计内涵和图 10.2 所示的威胁能力要素分类可以看出威胁能力模型包含:

- 指挥员设计与筹划能力模型;
- 作战资源获取能力模型;
- 资源调度、运用和补给能力模型;
- 这三种能力集成产生威胁实体的各种作战能力指数。

(2) 威胁意图模型主要包含:

- 高层意图, 通常是指上级或战役或战略意图和作战决心;
- 意图分解, 考虑威胁执行者内部承受能力, 对威胁任务(意图和指标)进行分解和下达;
- 预计(期望)的威胁对象和要达到的效果;
- 代理(机器计算或人)给出威胁行动结果的估计;
- 对上述诸点综合产生威胁意图, 即威胁对象及要达到的效果。

(3) 威胁机会模型主要包含:

- 防卫对象的可接近性, 如威胁对象的隐蔽/伪装措施、时间和空间上的薄弱点、防卫能力等;
- 可能遭遇的时间, 威胁实体达到攻击对象防区、突防、交战/攻击及撤出时间等;
- 最佳攻击时间估计, 包括全谱作战、战略和战术考量及战术分析和突发情况预测等;
- 考虑以上三点综合估计可能的威胁时机。

### 10.2.2 威胁估计的多假设推理<sup>[6]</sup>

多威胁实体——多对象威胁估计是采用威胁估计模型通过逐级多假设推理实现的。上述三类威胁估计模型支持威胁实体对威胁行动类型、威胁对象的选择和威胁时机的确定, 在威胁估计推理中起决定性的作用。威胁估计的多假设逐级推理过程如图 10.4 所示。

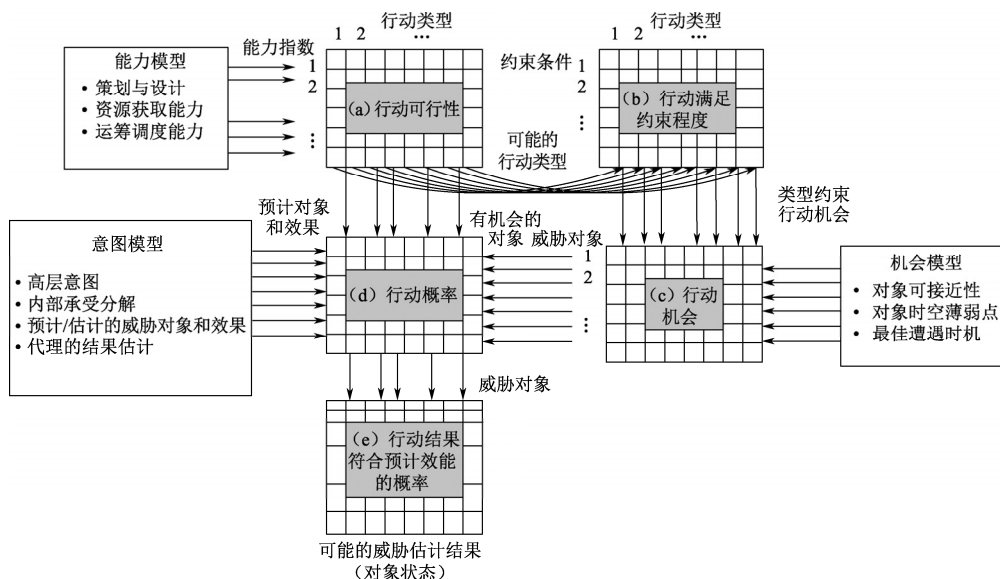


图 10.4 威胁估计的多假设逐级推理过程

对图 10.4 的几点说明如下：

- 3 个模型的输入是威胁实体（目标）的实时情报和非实时数据库信息（如防卫对象信息、作战条令/条例和环境/外部条件等），其输出信息分别支持不同环节的推理；
- 5 个环节的推理皆围绕威胁行动类型进行，行动类型基于实体能力参数，通过环境约束、对象机遇推理和威胁意图推理最终确定，威胁行动类型又被称为威胁估计的第四要素；
- 每个级别的威胁估计都是对多配对假设的推理计算实现的，图 10.4 中表格（a）～（e）是相应推理环节的多配对假设。

各表格的功能内涵和生成内容表述如下。

表格（a）是在威胁能力模型支持下产生的实体威胁能力—行动类型可能性假设排序表。其中的元素是威胁实体具有的某一威胁能力进行某一类型威胁行动的可能性大小，或者说是威胁实体遂行某一类型威胁行动的可能概率；利用表格（a）基于实体的威胁能力对其采用的行动类型进行初步筛选，作为表格（b）的行动类型输入。

表格（b）是约束条件—行动类型可能性假设排序表。其中的元素是某一威胁行动类型对某一约束的满足程度（概率），利用表格（b）基于约束条件对实体采用的可能威胁行动类型进行二次筛选，作为表格（c）的可行行动类型输入。

表格（c）是在机会模型支持下产生的威胁对象—行动类型机会假设排序表。其中的元素是一个威胁行动类型对某一威胁对象具有行动机会的概率，利用表格（c）基于威胁对象的机会模型对威胁实体采用的行动类型进行 3 次筛选，作为表格（d）的输入。

表格（d）是在威胁意图模型支持下产生有机会的威胁对象—可行行动类型假设概率排序表。其中的元素是威胁实体的一个可行行动类型对具有机会的对象满足威胁意图的行动概率。表格（d）是满足能力、约束条件，并具有行动机会的威胁实体的行动类型—威胁对象的预测概率，作为表格（e）的输入。

表格（e）是获得威胁实体的行动类型—威胁对象行动结果概率排序表。其中的元素是对表格（d）中相应元素进行蒙特卡洛仿真或基于实际威胁活动统计获得的，既可以对表格（d）给出的预测概率进行验证，也可作为最终的威胁估计的依据。

### 10.2.3 威胁估计推理中的多假设评估

在如图 10.4 所示的威胁估计推理过程中，每一级推理都通过对相应表格中的多假设配对元素进行评估，选择产生相应的推理结果，为下一级推理提供依据。在单/多威胁实体—多威胁对象背景下，威胁估计各级推理中相应的评估过程如下。

一级评估：实体威胁行动可能性评估。基于威胁能力模型对行动类型—威胁实体能力排序表（其中威胁能力可由一个或多个实体提供）中的每一（类型、能力）配对假设进行匹配计算，对计算结果归一化产生每一配对的可能概率，作为威胁实体采用各类威胁行动的可能性评估结果，基于门限判定剔除不可能的配对，生成图 10.4 中的表格（a）。

二级评估：威胁行动约束评估。对一级评估给出的图 10.4 表格（a）中威胁实体采取的

诸可能行动类型进行各类约束条件判断, 确定实体每一(类型、约束)配对假设的可能概率, 即对约束条件的满足程度, 基于门限判定能够剔除低可行概率的配对假设, 生成图 10.4 中的表格(b)。二级评估结果是对一级评估结果的精炼。

三级评估: 威胁对象机会评估。基于威胁对象机会模型, 对二级评估给出的图 10.4 表格(b)中威胁实体的可行行动类型与每一威胁对象的配对(类型、对象)假设进行可能机会匹配计算, 产生威胁实体的每个类型行动对每个对象实施机会概率, 基于门限判定剔除机会较小的配对假设, 产生图 10.4 中的表格(c)。基于机会模型的三级评估通过与威胁对象的关联, 实现对二级评估产生行动类型的再次精炼过程。

四级评估: 威胁行动概率预测。在威胁意图模型支持下, 对三级评估图 10.4 表格(c)中给出的具有一定行动机会的(类型、对象)配对假设, 通过与威胁意图相关联, 计算实体对威胁对象采取相应类型行动的概率预测, 通过门限判定剔除不可能的配对行动, 产生图 10.4 中的表格(d)诸元素。四级评估是对图 10.4 表格(c)给出的配对假设基于威胁意图进行的三次精炼过程。

五级评估: 威胁行动结果预测。对四级评估给出的图 10.4 表格(d)各配对元素进行仿真或实际威胁估计结果统计, 能够获得各配对行动产生的结果满足预计威胁效果的程度, 通过门限判定剔除不满足预计行动效果的配对假设, 得到图 10.4 中的表格(e)。结合图 10.4 中的表格(d)、表格(e)给出的行动概率和产生预计行动结果的概率, 经综合优化能够得到包括威胁实体、防卫对象、行动类型和机会在内的最优威胁估计, 进而确定各威胁实体的威胁值、威胁等级或威胁排序。

威胁估计的逐级评估过程如图 10.5 所示。

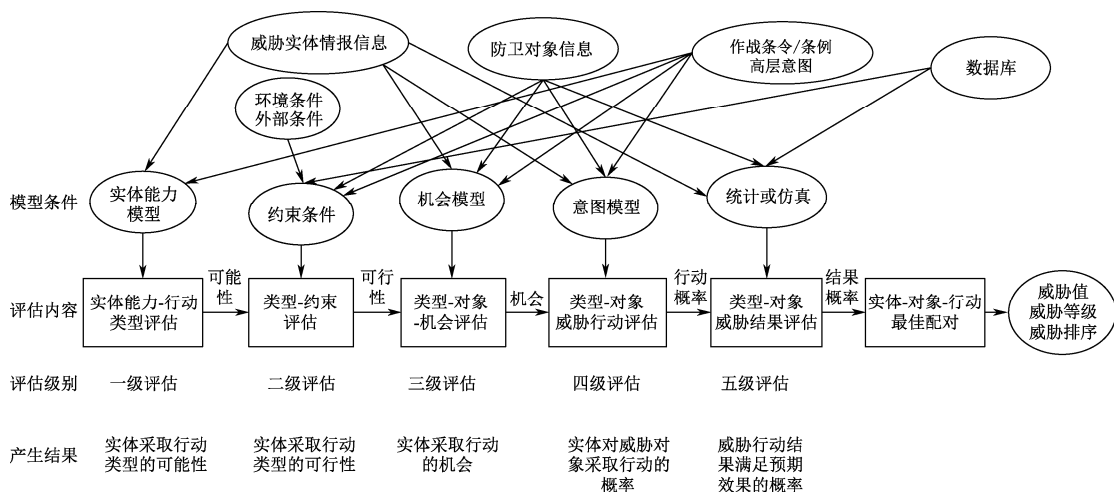


图 10.5 威胁估计的逐级评估过程

从图 10.5 中可以看出, 能力模型和约束条件用于对实体可能采取的行动类型进行推断、评估和精炼, 而实体能力模型、对象机会模型和威胁意图模型全部用于实体对防卫对象的威胁行动和行动结果的评估, 最终确定实体—对象—行动的最佳威胁估计配对。需指出的是, 基于实体能力和对象机会进行威胁行动估计比较容易实现和验证, 但对于蓄意攻击行动来说

并不是充分条件。在蓄意攻击行动中,意图才是威胁估计的重要因素,其对基于能力和机会确定的威胁行动和对象的最终评估选择起决定性作用,如图 10.5 所示的四级评估。还需指出的是,四级评估和五级评估计算都需要采用能力模型、机会模型和意图模型,可见,这 3 个模型是威胁估计的核心。

从图 10.5 中还可以看出,该威胁估计逐级推理与假设评估,特别是所运用的 3 个核心模型的输入信息包括关于威胁实体的情报信息、防卫对象信息、环境和外部约束条件,以及威胁实体的高层意图和作战条令/条例等。而该威胁估计的输出结果是基于实体—对象—行动最佳配对参数的实体—对象威胁值、威胁时间及威胁等级或威胁排序。

## 10.3 威胁估计方法

目标威胁估计是基于目标状态和属性估计及预测的态势进行目标综合威胁评价<sup>[9-15]</sup>。威胁估计方法从技术实现角度可以分为 3 类<sup>[7]</sup>:

- ① 产生式规则方法,是基于威胁要素进行威胁估计普遍采用的方法,但完备性不够,可能存在诸多无法辨识的情况;
- ② 对各威胁要素产生的威胁结果进行加权综合及其变型方法,为国内外军事指挥控制系统威胁估计普遍采用,实现容易、计算量小,缺点是结论不直观,无法回溯且与人的思维有较大差异;
- ③ 基于贝叶斯网络和模式识别理论对各要素产生的威胁结果进行综合传递的威胁估计方法,理论严密,但约束条件苛刻,与工程应用有较大差距。

### 10.3.1 基于随机区间的目标威胁估计方法

该方法是对加权综合估计方法的改进,针对加权综合估计存在的两个问题如下:

- ① 各威胁目标同一威胁要素的归一化处理问题,是由于各目标的同一威胁要素对不同攻击对象归一化尺度不同引起的。如对于距离要素来说,火箭筒以 1000 m 以内的目标作为主要打击对象,坦克以 3000 m 以内的目标作为主要打击对象,导弹则以 3000 m 以外的目标作为主要打击对象,对于同样的 1500 m 距离的目标,这 3 种武器的威胁效能显然不同,归一化指标并不能反映真实效用。
- ② 确定各威胁要素的权重存在困难,不同威胁要素相互独立,对威胁的重要程度无法准确估计。

#### 1. 确定目标威胁要素权重的方法

确定威胁要素权重主要有两类方法:

主观赋权法:基于决策者主观偏好的方法,如特征向量法、最小平方和法和 Delphi 法。主观赋权法具有较大的主观随意性,且易受决策者知识和经验缺失的影响;

客观赋权法:基于多因素决策矩阵信息的方法,如主成分分析法、信息熵法和多目标优化方法等,理论完善,但忽略了决策者的经验和偏好信息<sup>[12-16]</sup>。

这里采用将这两种方法优势进行集成的威胁要素权重确定方法。

### (1) 确定威胁要素权重相邻指标的两两比较法

该方法包含几下 4 个步骤:

#### ① 判定指标集 $X$ 中 $m$ 个指标重要性由大到小排序:

$$x^{(1)} > x^{(2)} > \dots > x^{(m)} \quad (10.1)$$

这里的指标  $x^{(i)} \in X$  表示第  $i$  个威胁要素,  $i=1, 2, \dots, m$ , 其重要性大小排序是由专家给出的。

② 由式 (10.1) 对  $X$  中的  $m$  个指标按照威胁重要性进行二元两两比较, 得到威胁要素重要性模糊标度矩阵  $\beta$ :

$$\beta = \begin{bmatrix} \beta_{11} & \beta_{12} & \dots & \beta_{1m} \\ \beta_{21} & \beta_{22} & \dots & \beta_{2m} \\ \dots & \dots & \dots & \dots \\ \beta_{m1} & \beta_{m2} & \dots & \beta_{mm} \end{bmatrix} \quad (10.2)$$

其中, 元素  $\beta_{ik}$  为指标  $x^{(i)}$  对  $x^{(k)}$  的相对重要性模糊标度值,  $0 \leq \beta_{ik} \leq 1$ ,  $\beta_{ik} + \beta_{ki} = 1$ ,  $\beta_{ii} = 0.5$ 。

#### ③ $\beta$ 矩阵诸元素的确定方法如下:

- 相邻指标相对重要性模糊标度  $\beta_{i,i+1}$  的求取。

领域专家给出了相邻威胁指标  $x^{(i)}$  与  $x^{(i+1)}$  的相对重要程度概念与对应的模糊标度值, 按表 10.1 即可查阅得到相应的模糊标度值  $\beta_{i,i+1}$ 。

表 10.1 相邻威胁指标相对重要程度与模糊标度值

重要程度	同样	稍微	略微	较为	明显	显著	十分	非常	极其	极端	无可比拟
模糊标度值	0.50	0.55	0.60	0.65	0.70	0.75	0.80	0.85	0.90	0.95	1.00

- $\beta_{ik} (|i-k| > 1)$  元素的求取。

由表 10.1 确定的  $\beta_{ii}$  和  $|i-j|=1$  的  $\beta_{ij}$ , 求取矩阵  $\beta$  中  $|i-k| > 1$  的任一威胁要素模糊标度值,  $\beta_{ik}$  的算法如下:

$$\begin{cases} \beta_{ik} (i < k-1) = \beta_{i,k-1} + 2(1-\beta_{i,k-1})(\beta_{k-1,k} - 0.5) & i = k-2, k-1, \dots, 1 \\ \beta_{ik} (i > k) = 1 - \beta_{ik} (i < k) \end{cases} \quad (10.3)$$

#### ④ 计算威胁要素指标权重。

由矩阵  $\beta$  元素  $\beta_{ij}$  的概念, 可知  $x^{(i)}$  与  $x^{(j)}$  的权重比  $w_i / w_j = \beta_{ij} / \beta_{ji} = \beta_{ij} / (1 - \beta_{ji})$ , 即

$$\beta_{ij} = \frac{w_i}{w_i + w_j} \quad i, j = 1, 2, \dots, m \quad (10.4)$$

由式 (10.4) 不难导出

$$\begin{aligned} \tilde{w}_1 &= \frac{\beta_{12}}{1 - \beta_{12}} \tilde{w}_2 = \dots = \frac{\beta_{12}}{1 - \beta_{12}} \frac{\beta_{23}}{1 - \beta_{23}} \dots \frac{\beta_{m-1,m}}{1 - \beta_{m-1,m}} \tilde{w}_m \\ &= \prod_{k=1}^{m-1} a_k \tilde{w}_m \end{aligned}$$

式中,  $a_k = \frac{\beta_{k,k+1}}{1 - \beta_{k,k+1}}$ ,  $k=1, 2, \dots, m-1$ 。

同理, 可以导出:

$$w_2 = \prod_{k=2}^{m-1} a_k w_m \cdots w_{m-1} = a_{m-1} w_m$$

再注意完备性  $w_1 + w_2 + \cdots + w_m = 1$ ，得到

$$w_i = \frac{\prod_{j=i}^{m-1} a_j}{\sum_{k=1}^{m-1} \prod_{j=k}^{m-1} a_j + 1} \quad i = 1, 2, \cdots, m-1 \quad (10.5)$$

$$w_m = \frac{1}{\sum_{k=1}^{m-1} \prod_{j=k}^{m-1} a_j + 1} \quad (10.6)$$

## (2) 确定威胁要素权重的统计秩和法

以问卷的形式要求  $n$  个领域专家对  $m$  个威胁要素  $x_1, x_2, \cdots, x_m$  进行重要程度评定，并要求每位专家对这  $m$  个威胁要素的重要程度进行排序。每个威胁要素所排序号被称为该要素的秩。对  $n$  位专家对一个要素的排序序号求和被称为该要素的秩和，表示为  $R$ ，于是第  $j$  个要素权重  $w_j$  的计算公式为

$$w_j = \frac{2[n(m+1) + R_j]}{nm(1+m)} \quad (10.7)$$

其中， $R_j$  为第  $j$  个要素的秩和。

统计秩和算法确定要素权重算法简单、清晰，已广泛用于心理学、教育学、生物学等领域对未知因素的权重计算，缺点是显然的，其仅受排序这一简单法则约束。

## (3) 确定威胁要素权重的统计分布法

仍然以问卷形式要求  $n$  个领域专家对  $m$  个威胁要素  $x_1, x_2, \cdots, x_m$  进行重要程度评定，但要求每位专家对要素  $x_i$  给出威胁重要程度的分布区间，即  $w_{ij} = [w_{ij}^L, w_{ij}^U] \subset [0, 1]$ ， $i = 1, 2, \cdots, m$ ， $j = 1, 2, \cdots, n$ ，于是  $x_i$  的权重  $w_i$  的概率分布可以表示为

$$w_i \sim \frac{1}{n} \sum_{j=1}^n [w_{ij}^L, w_{ij}^U] \quad i = 1, 2, \cdots, m \quad (10.8)$$

满足完备性条件  $\sum_{i=1}^m w_i = 1$ 。

若假设  $w_{ij}$  在  $[w_{ij}^L, w_{ij}^U]$  上服从均匀分布，则很难求出  $w_i$  的显式表达式，但我们仅是利用  $w_i$  求解多因素威胁估计问题，并不需要求解分布表达式，利用蒙特卡洛仿真容易求出在区间  $[w_{ij}^L, w_{ij}^U]$  上服从均匀分布的样本  $\tilde{w}_{ij}$  ( $j = 1, 2, \cdots, n$ )，利用该样本集合，按式 (10.8) 求取权重样本  $w_i$ ，并不影响计算目标威胁值。

统计分布法确定因素权重的理论优势在于：

- 充分吸取领域专家的意见，体现了群体决策特性；
- 与专家排序无关，即平等对待各专家给出的分布区间；
- 体现了有限专家意见的局限性，用概率分布表示不确定性具有可理解的随机性质；
- 专家意见的区间化表达和处理，体现了专家经验的不确定性。

该方法的缺陷是要有充分多的专家才能充分体现权重的统计特性，并且样本容量对信息量产生影响。

## 2. 目标威胁的效用函数

在目标威胁估计中,不同威胁目标关于同一威胁要素的威胁效用值相差太大,无法确定同一要素威胁效用的归一化基准(最大值)。这里以装甲目标威胁效用的无量纲归一化过程为例,提出一种目标威胁效用归一化的计算方法。其中,确定目标类别要素的效用函数(战斗力指数)和基于目标的毁伤状态要素效用函数采用随机区间方法,而确定基于目标距离、速度和航向角等威胁要素的效用函数采用效用曲线来表示。

### (1) 基于目标类别要素的威胁效用函数

装甲目标型号类别有反坦克火箭筒、反坦克导弹发射车、反坦克自行火炮、坦克、步兵战车等。

各类别威胁目标的效用函数是以随机区间表示的战斗力指数,归一化为

$$\tilde{I}_i = \frac{[I_i^L, I_i^U]}{\max\{I_j^U, j=1, 2, \dots, n\}} \quad i=1, 2, \dots, n \quad (10.9)$$

这里由于装甲目标类别中各型号不同,因此战斗力指数存在差别,当无法判断具体型号时,采用区间表示更合理。例如,反坦克火箭筒的战斗力指数为[30,80],反坦克导弹的战斗力指数为[200,300],自行火炮的战斗力指数为[50,90],主战坦克的战斗力指数为[120,150],步兵战车的战斗力指数为[40,120]。由于 $\max\{I_i^U, i=1, 2, \dots, 5\} = 300$ ,因此上述装甲目标各型号类别的相对威胁效用值分别为:反坦克火箭筒为[1/10,4/15],反坦克导弹为[2/3,1],自行火炮为[1/6,3/10],主战坦克为[2/5,1/2],步兵战车为[2/15,2/5]。

### (2) 基于目标距离要素的威胁效用函数

目标与打击对象相对距离产生的威胁程度主要体现在打击效果上,通常采用随距离变化的射击命中概率或毁伤概率或二者之积进行效用估计。不同型号的装甲目标随距离变化的威胁效用函数有所不同。如果只有远距离限制,则通常采用右半梯形曲线表示;若同时具有远、近距离限制,则采用梯形曲线表示,如图 10.6 所示。




图 10.6 基于目标距离的威胁效用函数

在如图 10.6 (a) 所示的右半梯形效用曲线中,对于某型号主战坦克来说, $x_0 = 1200 \text{ m}$ , $x_1 = 3000 \text{ m}$ ;而对于反坦克火箭筒来说, $x_0 = 300 \text{ m}$ , $x_1 = 1000 \text{ m}$ 。反坦克导弹存在近距离(死区)限制,故采用如图 10.6 (b) 所示的梯形曲线。

### (3) 基于目标速度要素的威胁效用函数

地面装甲目标的速度越快,处于机动或冲击状态的可能性越大,而处于射击或攻击状态即具有威胁的可能性相对要小一些;而目标速度越慢,处于射击或攻击状态即具有威胁的可



能性相对较大。因此其随速度变化的威胁效用类似于图 10.6 (a) 所示的右半梯形曲线。例如, 某型主战坦克  $v_0=25$  km/h,  $v_1=60$  km/h; 某型步兵战车相应的  $v_0=35$  km/h,  $v_1=80$  km/h。

#### (4) 基于目标航向角要素的威胁效用函数

目标航向角是指目标航向与打击对象观测视线的夹角。随目标航向角变化的威胁效用曲线如图 10.7 所示。




图 10.7 随目标航向角变化的威胁效用曲线

如图 10.7 所示, 当目标航向角为  $-30^\circ \sim +30^\circ$ , 即威胁目标基本面对打击对象时, 威胁度为最大值 1; 当目标航向角超出  $-90^\circ \sim +90^\circ$  时, 即完全脱离目标观测视线的打击对象不受威胁, 威胁效用值为 0。

#### (5) 基于目标毁伤状态的威胁效用函数

装甲目标处于不同的毁伤状态, 剩余的威胁效用也会出现相应的变化, 仍用随机区间表示为: 未被毁伤的威胁度量化为  $[0.70, 1.0]$ , 中等毁伤的威胁度量化为  $[0.40, 0.70]$ , 严重毁伤的威胁度量化为  $[0.0, 0.40]$ , 报废的威胁度量化为 0。

### 3. 基于随机区间的装甲目标威胁估计实现案例

基于 10.3.1 节给出的基于专家问卷方式的统计分布法确定 5 个目标威胁要素权重, 对于我们这里的装甲目标来说, 能够得到 5 个威胁要素的权重分别为: 型号类别要素权重为 0.32, 相对距离要素权重为 0.24, 相对速度要素权重为 0.18, 目标航向角要素权重为 0.14, 目标毁伤状态权重为 0.12。

在给出装甲目标各威胁要素相应型号类别和运动与毁伤状态参数之后, 按前文给出的装甲目标 5 个威胁要素的效用函数计算方法, 得到如表 10.2 所示的 5 个目标各威胁要素归一化效用区间。

表 10.2 装甲目标 5 个要素的威胁效用区间

目 标	类 别	距 离	速 度	航 向 角	毁 伤 状 态
$T_1$	$[0.5, 0.6]$	$[0.416, 0.534]$	$[0.876, 0.962]$	$[0.487, 0.926]$	$[0.961, 0.971]$
$T_2$	$[0.5, 0.6]$	$[0.923, 0.939]$	$[0.970, 0.990]$	$[0.950, 0.977]$	$[0.527, 0.613]$
$T_3$	$[0.90, 0.94]$	$[0.920, 0.929]$	$[0.985, 1.000]$	$[0.720, 0.730]$	$[0.985, 1.000]$
$T_4$	$[0.80, 0.90]$	$[0.236, 0.325]$	$[0.753, 0.798]$	$[0.320, 0.330]$	$[0.755, 0.898]$
$T_5$	$[0.4, 0.5]$	$[0.703, 0.835]$	$[0.950, 0.970]$	$[0.198, 0.210]$	$[0.975, 1.000]$

假设 5 个目标各要素威胁效用值在表 10.2 的效用区间内服从均匀分布, 那么通过  $10^6$

次蒙特卡洛采样, 可得到每个目标的 5 要素加权综合威胁效用值的频数直方图, 并拟合得到各目标综合威胁值的正态“钟形”分布曲线, 如图 10.8 所示。




图 10.8 各装甲目标综合威胁效用值频数直方图及与接近的分布曲线

从图 10.8 (a) ~ 图 10.8 (e) 各目标综合威胁效用值频数直方图及其与正态分布曲线拟合情况可以看出, 简单地认为在目标各要素威胁效用服从均匀分布的前提下, 获得的目标综合威胁效用服从均匀分布或正态分布, 并依次进行威胁估计方法比较, 在理论依据上并不充分。

鉴于无法准确确定目标综合威胁效用的统计分布, 为了基于综合威胁效用对各目标进行威胁排序, 我们在产生如图 10.8 所示的各目标综合威胁效用值频率直方图的仿真过程中, 直接对各目标综合威胁效用进行两两比较统计, 基于统计次数得到大小比较可能概率为

$$p_{ij} = P_r(u_i \geq u_j) \quad i, j = 1, 2, \dots, 5$$

采用前文中的相邻指标两两比较法, 可以基于 5 个目标综合威胁效用比较可能概率, 得到两两比较的可能度矩阵为

$$P = \begin{bmatrix} - & 0 & 0 & 1 & 0.79 \\ 1 & - & 0 & 1 & 1 \\ 1 & 1 & - & 1 & 1 \\ 0 & 0 & 0 & - & 0 \\ 0.21 & 0 & 0 & 1 & - \end{bmatrix}$$

对该矩阵中同行元素求和, 可以得到本例中 5 个目标综合威胁可能度向量为

$$\mathbf{v} = (v_1, v_2, \dots, v_5) = (1.79, 3, 4, 0, 1.21)$$

于是,各目标威胁估计排序为

$$S_3 > S_2 > S_1 > S_5 > S_4$$

从而目标  $S_3$  威胁最大,  $S_2$  次之,其余类推。

采用另一种空中目标威胁估计方法<sup>[8]</sup>,基于区间均匀分布定义可能度,得到本例中 5 个目标综合威胁可能度两两比较矩阵为

$$P = \begin{pmatrix} - & 0 & 0 & 0.71 & 0.60 \\ 1 & - & 0 & 1 & 1 \\ 1 & 1 & - & 1 & 1 \\ 0.29 & 0 & 0 & - & 0.34 \\ 0.40 & 0 & 0 & 0.66 & - \end{pmatrix}$$

由此得到本例中 5 个目标的综合威胁可能度向量为

$$v = (v_1, v_2, \dots, v_5) = (1.31, 3, 4, 0.73, 1.06)$$

5 个目标威胁估计排序为

$$S_3 > S_2 > S_1 > S_5 > S_4$$

尽管两种算法给出的排序结果相同,但经过分析可以看出,两种算法的目标 2 和目标 3 的威胁可能度取值相同(均为 3 和 4),但目标 1、目标 4 和目标 5 的威胁可能度却分别相差了 0.48、0.73 和 0.05,说明仅依赖威胁区间长度主观认为在区间上服从均匀分布会降低威胁度排序的分辨能力,也说明了本节给出的直接基于目标威胁效用仿真统计求取威胁效用大小比较的可能度能够更容易进行目标威胁度的分辨和排序。

本节给出的基于随机区间的目标威胁估计方法及应用案例展现了如下优势:

- 采用各威胁要素区间均匀分布计算其效用及权重,生成目标综合威胁效用,该框架具有多目标多要素威胁估计应用的普适性,对当前网络中心战环境中多域多类威胁估计具有应用价值;
- 本节提出的目标多要素综合威胁度排序的可能度统计计算方法避开了具体分布形式,其威胁度排序的分辨力明显高于某一单一分布下的威胁度排序分辨能力;
- 威胁要素区间均匀分布的假定并非必要,只要适当改造蒙特卡洛仿真算法的随机数产生部分,即可应用于其他区间的分布类型,如三角分布、梯形分布等,因此本节所述威胁估计框架具有概率分布的适应性。

### 10.3.2 基于模糊模式识别的目标威胁估计算法

本节针对水面舰艇编队防空作战建立空中目标对水面舰艇威胁等级的模糊识别模型,为进行空中目标威胁判断提供一种技术途径,这里将目标不同的威胁要素称为威胁属性,在基于模糊识别的空中目标威胁估计中,目标威胁属性包括相对距离、相对速度、目标高度、航路捷径及目标类型 5 种,而每种属性产生的威胁效用采用威胁隶属度表示。

#### 1. 模糊模式识别模型<sup>[16]</sup>

待识别的目标(样本)集合为  $X = \{x_1, x_2, \dots, x_n\} \in \mathbf{R}^{m \times n}$ ,  $n$  为目标数。每个目标具有  $m$

个威胁属性, 对  $n$  个目标的威胁级别估计所采用的模糊模式识别知识包括如下内容。

### (1) 目标威胁属性的归一化处理

为消除  $m$  个威胁属性物理量纲不同产生的影响, 需将目标  $X$  属性样本矩阵归一化变换为无量纲数据矩阵

$$R_{m \times n} = (r_{ij})_{m \times n} \quad 0 \leq r_{ij} \leq 1 \quad i=1, \dots, n \quad j=1, \dots, m \quad (10.10)$$

其中,  $r_{ij}$  表示第  $i$  个目标的第  $j$  个威胁属性取值。目标威胁属性的归一化变换方法主要有统计变换法和标准变换法两类。

#### ① 统计变换法。

设  $x_{k_1}, x_{k_2}, \dots, x_{k_n}$  为  $n$  个目标的第  $k$  个威胁属性的取值 (威胁属性隶属度),  $k=1, 2, \dots, m$ , 威胁属性隶属度归一化步骤如下。

求均值:

$$\bar{x}_k = \frac{1}{n} (x_{k_1} + x_{k_2} + \dots + x_{k_n}) \quad k=1, 2, \dots, m$$

求样本标准差:

$$S_k = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_{k_i} - \bar{x}_k)^2} \quad k=1, 2, \dots, m$$

计算威胁属性归一化取值:

$$r_{k_i} = (x_{k_i} - \bar{x}_k) / S_k \quad k=1, 2, \dots, m \quad i=1, 2, \dots, n \quad (10.11)$$

#### ② 标准变换法。

效益型威胁属性归一化取值为

$$r_{k_i} = \frac{r_{k_j} - x_k^{\min}}{x_k^{\max} - x_k^{\min}} \quad k=1, 2, \dots, m \quad i=1, 2, \dots, n \quad (10.12)$$

成本型威胁属性归一化取值为

$$r_{k_i} = \frac{x_k^{\max} - r_{k_j}}{x_k^{\max} - x_k^{\min}} \quad k=1, 2, \dots, m \quad i=1, 2, \dots, n$$

其中,  $x_k^{\min} = \min_i \{x_{k_i}\}, x_k^{\max} = \max_i \{x_{k_i}\}$ 。

### (2) 威胁级别相对隶属度矩阵和属性归一化矩阵

$n$  个目标 (样本) 对各威胁级别的相对隶属度矩阵为

$$U = (u_{hj})_{c \times n} \quad (10.13)$$

$$\sum_{h=1}^c u_{hj} = 1 \quad \sum_{j=1}^n u_{hj} > 0 \quad 0 \leq u_{hj} \leq 1 \quad j=1, 2, \dots, n \quad h=1, 2, \dots, c$$

其中,  $c$  为威胁等级数; 元素  $u_{hj}$  为目标  $j$  对威胁级别  $h$  的隶属度, 是最终要确定的威胁估计值。

各威胁级别关于  $m$  个威胁属性归一化矩阵

$$S = (s_{ih})_{m \times c} \quad (10.14)$$

其中, 元素  $s_{ih}$  为威胁级别  $h$  上关于属性  $i$  的归一化值, 可使用聚类分析方法, 将每一威胁属

性的聚类均值作为归一化基准。

(3) 威胁属性在威胁估计中的权重向量

$$\mathbf{W} = (w_1, w_2, \dots, w_m) \quad \sum_{k=1}^m w_k = 1 \quad 0 < w_k < 1 \quad (10.15)$$

(4) 目标  $j$  (基于  $m$  个威胁属性取值) 与威胁级别  $h$  之间的综合差异 (广义欧式距离)

$$d_{hj} = \sqrt{\sum_{i=1}^m [w_i (r_{ij} - s_{ih})]^2} \quad (10.16)$$

目标  $j$  与威胁级别  $h$  之间的加权广义欧式距离

$$D_{hj} = u_{hj} \times d_{hj} = u_{hj} \times \sqrt{\sum_{i=1}^m [w_i (r_{ij} - s_{ih})]^2} \quad (10.17)$$

(5) 威胁估计模糊模式识别模型的指标函数为使所有目标与所有威胁级别之间的距离平方和最小

$$J = \min \left\{ F(\mathbf{U}) = \sum_{j=1}^n \sum_{h=1}^c u_{hj}^2 \sum_{i=1}^m [w_i (r_{ij} - s_{ih})]^2 \right\} \quad (10.18)$$

约束条件为

$$\sum_{h=1}^c u_{hj}^2 = 1, \quad 0 \leq u_{hj} \leq 1, \quad \sum_{j=1}^n u_{hj} > 0, \quad j = 1, 2, \dots, n, \quad h = 1, 2, \dots, c$$

(6) 模糊模式识别模型求解概念

该威胁估计模型中要求解的变量是各目标对威胁级别的相对隶属度矩阵  $\mathbf{U}$ , 不难看出, 隶属度矩阵  $\mathbf{U}$  与威胁属性权重向量  $\mathbf{W}$ , 以及威胁级别关于威胁属性的归一化矩阵  $\mathbf{S}$  耦合在一起, 因此该模型的求解变量是  $u_{kj}$ ,  $w_i$  和  $s_{ih}$  ( $i = 1, 2, \dots, m$ ,  $j = 1, 2, \dots, n$ ,  $h = 1, 2, \dots, c$ )。

基于最小二乘法可获得使式 (10.18) 达到极小的最优解。在该最优解中, 目标  $j$  对威胁级别  $h$  的隶属度  $u_{hj}$  的取值与广义欧氏距离  $d_{hj}$  的关系为

$$u_{hj} = \begin{cases} 1 & d_{hj} = 0 \\ d_{hj}^2 / \sum_{k=1}^c d_{kj}^2 & d_{hj} \neq 0 \\ 0 & d_{hj} = 1 \end{cases} \quad (10.19)$$

其中,  $d_{hj} = \sqrt{\sum_{i=1}^m [w_i (r_{ij} - s_{ih})]^2}$  为目标  $j$  与威胁级别  $h$  (基于  $m$  个威胁属性) 的综合差异 (广义欧氏距离);  $r_{ij}$  为式 (10.10) 定义的目标  $j$  的第  $i$  个威胁属性隶属度。

(7) 目标  $j$  的威胁等级

根据威胁分级之下的最大隶属度原则, 确定目标  $j$  威胁级别的模糊均值为

$$H_j = \sum_{h=1}^c h \times u_{hj} \quad j = 1, 2, \dots, n \quad (10.20)$$

## 2. 目标威胁属性值的模糊确定

空中来袭目标各威胁属性的取值采用模糊集理论中的隶属度 (隶属函数) 表示。

## (1) 基于相对距离的威胁隶属函数

空中目标与可能攻击对象的距离越小, 威胁程度越大, 故相对距离隶属函数通常选取降岭形分布函数

$$r_2 = \begin{cases} 0 & d \leq d_{\min} \\ \frac{1}{2} - \frac{1}{2} \sin \frac{\pi C}{d_{\max} - d_{\min}} & d_{\min} < d \leq d_{\max} \\ 1 & d > d_{\max} \end{cases} \quad (10.21)$$

式中,  $C = d - \frac{d_{\max} + d_{\min}}{2}$ ;  $d_{\max}$  和  $d_{\min}$  分别为无威胁和威胁最大的两个临界距离。

## (2) 基于相对速度的威胁隶属函数

空中目标逼近攻击对象的速度越快, 威胁程度越大; 当逼近速度超过极限值  $v_1$  时, 威胁程度为最大值 1。空中目标飞离攻击对象的速度越快, 威胁程度越小; 当飞离速度小于等于极限值  $v_2$  时, 威胁程度达极小值 0。于是, 目标相对速度的威胁隶属函数呈升岭分布

$$r_2 = \begin{cases} 0 & v_{\text{飞离}} \leq v_2 \\ \frac{1}{2} + \frac{1}{2} \sin \left[ \frac{\pi}{v_1 - v_2} \right] & v_2 \leq v \leq v_1 \\ 1 & v_{\text{逼近}} > v_1 \end{cases} \quad (10.22)$$

式中, 注意飞离速度  $v_{\text{飞离}} < 0$ , 逼近速度  $v_{\text{逼近}} > 0$ 。

## (3) 基于目标高度的威胁隶属函数

目标高度  $h$  小于  $h_0$  时, 将对防卫方进行低空攻击, 其威胁值最大。随着目标高度的增大, 其威胁程度逐渐减小。因此, 目标高度威胁函数可看作降半  $\Gamma$  分布, 即

$$r_3 = \begin{cases} 1 & 0 < h \leq h_0 \\ e^{-k(h-h_0)^2} & h > h_0 \end{cases} \quad (10.23)$$

式中,  $k$  为常数。

## (4) 基于目标航路捷径的威胁隶属函数

在不考虑目标机动的情况下, 随着对攻击对象航路捷径  $p$  的增加, 目标的威胁程度下降, 故基于航路捷径的威胁隶属函数可视为线性函数

$$r_4 = \begin{cases} 0 & p \geq p_{\max} \\ (p_{\max} - p) / p_{\max} & p < p_{\max} \end{cases} \quad (10.24)$$

式中,  $p_{\max}$  为基于威胁的最大航路捷径门限。

## (5) 基于空中目标类型的威胁程度

不同类型空中目标的作战使命不同, 装备不同, 对水面舰艇编队的威胁程度也不同。其威胁程度通常采用确定性指标及符合我国语言习惯的互补方法<sup>[13]</sup>确定。在水面舰队防空作战中, 可能来袭空中目标的分类及威胁程度见表 10.3。

表 10.3 空中目标的分类及威胁程度

目标的分类	反舰导弹	歼轰机	歼击机	不明飞行物	直升机	电子战飞机	其他飞机
威胁程度	1.0	0.8	0.7	0.65	0.6	0.3	0.2

### 3. 半监督模糊模式识别模型及其迭代解法

在由指标函数式 (10.18) 和相应的隶属度矩阵  $\mathbf{U}$  各元素约束构成的目标威胁级别模糊模式识别模型中, 除模型的规划变量矩阵  $\mathbf{U}$  之外, 还含有与矩阵  $\mathbf{U}$  紧密耦合的目标威胁属性权重向量  $\mathbf{W}$  和威胁级别对威胁属性的归一化矩阵  $\mathbf{S}$ 。

对该空中目标威胁等级的模糊模式识别模型求解, 要充分利用大量战例积累的战场数据库中的目标威胁等级知识, 它们是军事专家从大量典型场景的分析中提取出来的; 战场数据库中还含有许多未识别出威胁等级的目标和场景; 有的目标威胁等级知识还要随新出现的场景进行不断的改进和完善。

本节采用已知威胁等级的目标样本作为监督, 建立含有三类变量  $\mathbf{U}$ 、 $\mathbf{W}$  及  $\mathbf{S}$  的关于目标威胁等级的模糊模式识别模型的求解算法。

#### (1) 半监督威胁等级模糊模式识别模型

假设条件: 设有  $n$  个目标样本, 每个目标样本对应  $m$  个属性:  $X = \{x_1, x_2, \dots, x_n\} \in \mathbf{R}_{m \times n}$ ,  $n$  个目标样本  $m$  个威胁属性取值的隶属度矩阵  $\mathbf{R}_{m \times n} = (r_{ij})_{m \times n}$  ( $0 \leq r_{ij} \leq 1$ )。已知样本集  $X$  中  $n_1 (< n)$  个样本的威胁等级, 未知威胁等级的样本有  $n_2$  个,  $n_1 + n_2 = n$ 。

定义监督矩阵

$$\mathbf{F} = \begin{pmatrix} f_{11} & f_{12} & & f_{1n_1} & 0 & 0 \\ f_{21} & f_{22} & & f_{2n_1} & 0 & 0 \\ \vdots & \vdots & \dots & \vdots & \vdots & \vdots \\ f_{c1} & f_{c2} & & f_{cn_1} & 0 & 0 \end{pmatrix} = (f_{hj})_{c \times n} \quad (10.25)$$

式中,  $f_{hj}$  为样本  $j$  的威胁等级  $h$  的监督项,  $0 \leq f_{hj} \leq 1$ ; 对于已知威胁等级的  $n_1$  个样本, 存在  $f_{hj} = \begin{cases} 1 & h = h_j \\ 0 & \text{其他} \end{cases}$  ( $j = 1, 2, \dots, n_1$ ,  $h = 1, 2, \dots, C$ ); 对未知威胁等级的  $n_2$  个样本,  $f_{hj} = 0$  ( $j = n_1 + 1, \dots, n$ ,  $h = 1, 2, \dots, C$ )。

半监督规则模型: 在式 (10.18) 定义的指标函数中引入监督项  $f_{hj}$ , 使其成为

$$J_\alpha = \min \{F_\alpha(\mathbf{U}, \mathbf{S}, \mathbf{W})\}$$

$$F_\alpha(\mathbf{U}, \mathbf{S}, \mathbf{W}) = \sum_{j=1}^n \sum_{h=1}^c \left\{ (1-\alpha) u_{hj}^2 \sum_{i=1}^m [w_i (r_{ij} - s_{ih})]^2 + \alpha (u_{hj} - f_{hj})^2 \sum_{i=1}^m [w_i (r_{ij} - s_{ih})]^2 \right\} \quad (10.26)$$

式 (10.26) 满足约束条件

$$\sum_{h=1}^c u_{hj} = 1, \quad 0 \leq u_{hj} \leq 1, \quad \sum_{j=1}^n u_{hj} > 0$$

$$\sum_{i=1}^m w_i = 1, \quad 0 < w_i < 1, \quad 0 \leq s_{ih} \leq 1 \quad (10.27)$$

$$i=1,2,\cdots,m, \quad j=1,2,\cdots,n, \quad h=1,2,\cdots,c$$

式 (10.26) 中,  $\alpha$  为监督因子,  $0 \leq \alpha \leq 1$ 。

## (2) 模型求解

对半监督威胁等级非线性规划模型 (10.26) 构建拉格朗日加权的无约束指标函数

$$J_{\alpha}(U, S, W, \lambda_w, \lambda_j) = \sum_{j=1}^n \sum_{h=1}^c \left\{ \begin{aligned} & (1-\alpha)u_{hj}^2 \sum_{i=1}^m [w_i(r_{ij} - s_{ih})]^2 + \\ & \alpha(u_{hj} - f_{hj})^2 \sum_{i=1}^m [w_i(r_{ij} - s_{ih})]^2 \end{aligned} \right\} - \lambda_w \left( \sum_{i=1}^m w_i - 1 \right) - \lambda_j \left( \sum_{h=1}^c u_{hj} - 1 \right) \quad (10.28)$$

令

$$\frac{\partial L_{\alpha}}{\partial u_{hj}} = 0, \quad \frac{\partial L_{\alpha}}{\partial w_i} = 0, \quad \frac{\partial L_{\alpha}}{\partial \lambda_w} = 0, \quad \frac{\partial L_{\alpha}}{\partial \lambda_j} = 0 \quad (10.29)$$

可得到半监督模糊识别迭代模型为

$$s_{ih} = \frac{\sum_{j=1}^n [(1-\alpha)u_{hj}^2 + \alpha(u_{hj} - f_{hj})^2] r_{ij}}{\sum_{j=1}^n [(1-\alpha)u_{hj}^2 + \alpha(u_{hj} - f_{hj})^2]} \quad (10.30)$$

$$u_{hj} = af_{hj} + \left( 1 - a \sum_{k=1}^c f_{hk} \right) \sum_{k=1}^c f_{hk} \frac{\sum_{i=1}^m [w_i(r_{ij} - s_{ih})]^2}{\sum_{i=1}^m [w_i(r_{ij} - s_{ik})]^2} \quad (10.31)$$

$$w_i = \left\{ \frac{\sum_{h=1}^c \sum_{j=1}^n \left[ \left[ (1-a)u_{hj}^2 + a(u_{hj} - f_{hj})^2 \right] (r_{ij} - s_{ih})^2 \right]}{\sum_{k=1}^c \sum_{j=1}^n \left[ \left[ (1-a)u_{hj}^2 + a(u_{hj} - f_{hj})^2 \right] (r_{ij} - s_{kh})^2 \right]} \right\} \quad (10.32)$$

基于式 (10.30)、式 (10.31) 和式 (10.32) 的模型求解迭代步骤如下:

① 给出循环迭代计算精度  $\varepsilon_1$ 、 $\varepsilon_2$ 、 $\varepsilon_3$  及威胁等级数  $c$ ;

② 给出初始值, 包括  $m$  个威胁属性的权重向量为  $W^l = (w_i^l)_m$ 、 $c$  个威胁等级、 $m$  个属性的归一化矩阵  $(s_{ih}^l)_{m \times c}$ 、 $n$  个目标样本对  $c$  个威胁等级的隶属度矩阵  $(u_{hj}^l)_{c \times n}$ , 令  $l=0$ ;

③ 根据式 (10.30)、式 (10.31) 和式 (10.32) 分别计算  $(s_{ih}^{l+1})_{c \times n}$ 、 $(u_{hj}^{l+1})_{c \times n}$  和  $W^{l+1}$ ;

④ 判断:

$$\text{若 } \max_{1 \leq i \leq m} |w_i^{l+1} - w_i^l| < \varepsilon_w, \quad \max_{\substack{1 \leq h \leq c \\ 1 \leq j \leq n}} |u_{hj}^{l+1} - u_{hj}^l| < \varepsilon_u, \quad \max_{\substack{1 \leq i \leq m \\ 1 \leq k \leq c}} |s_{ih}^{l+1} - s_{ih}^l| < \varepsilon_s \quad (10.33)$$

则迭代结束, 转步骤⑤; 否则置  $l$  为  $l+1$ , 转步骤②继续迭代判断。

⑤ 迭代结束, 产生的向量  $(w_i^{l+1})_m$  和矩阵  $(s_{ih}^{l+1})_{m \times c}$  为满足精度要求的目标威胁属性权重



向量和满足威胁等级的属性归一化矩阵, 此时得到的  $(u_{hj}^{l+1})_{c \times n}$  为满足约束条件 (10.27) 并使半监督非线性规划模型指标函数 (10.26) 达极小的解矩阵。

(3) 关于半监督模糊模式识别模型迭代求解的收敛性

① 指标函数的边缘特性。

设区间  $I = [0, 1]$ , 则在  $[0, 1]$  中变化的模型规划变量 (矩阵或向量) 为  $S \in I^{m \times c}$ ,  $U \in I^{c \times n}$ ,  $W \in I^m$ , 按式 (10.26) 给出的半监督非线性规划指标函数为

$$J_\alpha = \min \{F_\alpha(U, S, W)\}$$

$$F_\alpha(U, S, W) = \sum_{j=1}^n \sum_{h=1}^c \left\{ (1-\alpha) u_{hj}^2 \sum_{i=1}^m [w_i (r_{ij} - s_{ih})]^2 + \alpha (u_{hj} - f_{hj})^2 \sum_{i=1}^m [w_i (r_{ij} - s_{ih})]^2 \right\} \quad (10.34)$$

若其中任意两个变量给定, 则  $F_\alpha(U, S, W)$  是另一个变量的严格凸函数, 可由以下 3 个定理表述。

定理1 对于给定的  $S \in I^{m \times c}$ 、 $U \in I^{c \times n}$ , 记

$$F_{SU}(W) = \sum_{j=1}^n \sum_{h=1}^c \left\{ (1-\alpha) u_{hj}^2 \sum_{i=1}^m [w_i (r_{ij} - s_{ih})]^2 + \alpha (u_{hj} - f_{hj})^2 \sum_{i=1}^m [w_i (r_{ij} - s_{ih})]^2 \right\} \quad (10.35)$$

则  $F_{SU}(W)$  是变量  $W \in I^m$  的严格凸函数。

证明: 求  $F_{SU}(W)$  对  $W$  的一阶、二阶偏导数分别为

$$\left\{ \begin{aligned} \frac{\partial F_{SU}(W)}{\partial w_i} &= 2w_i \left[ (1-\alpha) \sum_{j=1}^n u_{hj}^2 (r_{ij} - s_{ih})^2 + \alpha \sum_{j=1}^n (u_{hj} - f_{hj})^2 (r_{ij} - s_{ih})^2 \right] \\ \frac{\partial^2 F_{SU}(W)}{\partial w_i \partial w_q} &= \begin{cases} 2(1-\alpha) \sum_{j=1}^n u_{hj}^2 (r_{ij} - s_{ih})^2 + 2\alpha \sum_{j=1}^n (u_{hj} - f_{hj})^2 (r_{ij} - s_{ih})^2 & i=q \\ 0 & i \neq q \end{cases} \quad i, q=1, 2, \dots, m \end{aligned} \right. \quad (10.36)$$

可见,  $F_{SU}(W)$  关于  $W$  的 Hussein 矩阵是正定矩阵, 其对角线元素为正数, 其余元素值均为 0, 故  $F_{SU}(W)$  是变量  $W$  的严格凸函数。

定理2 对于给定的  $S \in I^{m \times c}$ 、 $W \in I^m$ , 记

$$F_{SW}(U) = \sum_{j=1}^n \sum_{h=1}^c \left\{ (1-\alpha) u_{hj}^2 \sum_{i=1}^m [w_i (r_{ij} - s_{ih})]^2 + \alpha (u_{hj} - f_{hj})^2 \sum_{i=1}^m [w_i (r_{ij} - s_{ih})]^2 \right\}$$

则  $F_{SW}(U)$  是变量  $U \in I^{c \times n}$  的严格凸函数。

定理3 对于给定的  $U \in I^{c \times n}$ 、 $W \in I^m$ , 记

$$F_{UW}(S) = \sum_{j=1}^n \sum_{h=1}^c \left\{ (1-\alpha) u_{hj}^2 \sum_{i=1}^m [w_i (r_{ij} - s_{ih})]^2 + \alpha (u_{hj} - f_{hj})^2 \sum_{i=1}^m [w_i (r_{ij} - s_{ih})]^2 \right\}$$

则  $F_{UW}(S)$  是变量  $S \in I^{m \times c}$  的严格凸函数。

② 指标函数的边缘极值点。

若式 (10.34) 所示  $F_\alpha(U, S, W)$  中的任意两个变量给定, 则由式 (10.30)、式 (10.31) 和式 (10.32) 计算的第三个变量使  $F_\alpha(U, S, W)$  达全局极小, 可由以下 3 个定理表述。

**定理 4** 对于给定的  $\mathbf{S} \in \mathbf{I}^{m \times n}$ 、 $\mathbf{U} \in \mathbf{I}^{c \times n}$ ，式 (10.32) 确定的  $\mathbf{W}$  是函数  $F_{\mathbf{SU}}(\mathbf{W})$  的全局极小解。

证明:  $\mathbf{S} \in \mathbf{I}^{m \times n}$ 、 $\mathbf{U} \in \mathbf{I}^{c \times n}$  给定, 则求解式 (10.32) 相当于求解式 (10.26) 在约束 (10.27) 下的非线性规划问题:

$$\min_{\mathbf{W}} \{F_{\mathbf{SU}}(\mathbf{W})\} \quad (10.37)$$

式 (10.37) 满足约束条件  $\sum_{i=1}^m w_i = 1$  ( $0 < w_i < 1$ ,  $i=1, 2, \dots, m$ )。

显而易见, 该问题的 Kuhn—Tacker 条件<sup>[17]</sup>为

$$2w_i = \left[ (1-\alpha) \sum_{j=1}^n u_{hj}^2 (r_{ij} - s_{ih})^2 + \alpha \sum_{j=1}^n (u_{hj} - f_{hj})^2 (r_{ij} - s_{ih})^2 \right] + \gamma + \beta_i = 0 \quad (10.38)$$

$$\sum_{i=1}^m w_i = 1 \quad (10.39)$$

$$w_i \beta_i = 0 \quad (10.40)$$

由于  $0 < w_i < 1$  ( $i=1, 2, \dots, m$ ), 故  $\beta_i = 0$ , 对式 (10.38) 求和, 得

$$\sum_{i=1}^m w_i = \sum_{i=1}^m \frac{-\gamma}{A+B} = 1 \quad (10.41)$$

其中,

$$\gamma = - \left[ \sum_{i=1}^m \frac{1}{A+B} \right]^{-1} \quad A = 2(1-\alpha) \sum_{j=1}^n \left[ u_{hj}^2 (r_{ij} - s_{ih})^2 \right]$$

$$B = 2\alpha \sum_{j=1}^n \left[ (u_{hj} - f_{hj})^2 (r_{ij} - s_{ih})^2 \right]$$

取式 (10.41) 表示的  $\gamma$ , 满足 Kuhn—Tucker 条件。定理 1 已证  $F_{\mathbf{SU}}(\mathbf{W})$  是变量  $\mathbf{W} \in \mathbf{I}^m$  的严格凸函数, 因此由式 (10.38) 确定的  $\mathbf{W}$  是  $F_{\mathbf{SU}}(\mathbf{W})$  的全局极小点。

**定理 5** 给定  $\mathbf{S} \in \mathbf{I}^{m \times n}$ 、 $\mathbf{W} \in \mathbf{I}^m$ , 由式 (10.31) 确定的  $\mathbf{U}$  是函数  $F_{\mathbf{SW}}(\mathbf{U})$  的全局极小点。

**定理 6** 给定  $\mathbf{U} \in \mathbf{I}^{c \times n}$ 、 $\mathbf{W} \in \mathbf{I}^m$ , 由式 (10.30) 确定的  $\mathbf{S}$  是指标函数  $F_{\mathbf{UW}}(\mathbf{S})$  的全局极小点。

定理 5 和定理 6 的证明过程与定理 4 类似。

基于定理 1~定理 6, 应用 Zangwill 定理及其多值映射的特定形式, 即可证明该半监督多目标威胁等级模糊模式识别模型 (10.26) 和 (10.27) 在上述迭代求解过程中的收敛性。

#### 4. 威胁估计模糊模式识别算法应用案例

在舰艇防空作战中, 来袭目标有 450 批。其中, 战场数据库中已知其中 100 批目标的威胁等级, 需要估计其余各批来袭目标的威胁等级。该应用案例以其中已知威胁等级的一批目标为监督目标, 要求确定三批未知威胁等级目标的威胁等级。用作监督目标的一批空中目标和需要进行威胁估计的三批空中目标的威胁属性分别见表 10.4 和表 10.5。

表 10.4 用作监督目标的一批空中目标的威胁属性

目标编号	距离/km	相对速度/(m/s)	高度/m	航路捷径/m	目标类型
$j$	28	230	50	0	歼轰机

表 10.5 需要进行威胁估计的三批空中目标的威胁属性

目标批号	距离/km	相对速度/(m/s)	高度/m	航路捷径/m	目标类型
1	100	200	1000	3000	电子战飞机
2	50	250	3000	50	不明飞行物
3	30	300	60	0	歼轰机

该应用案例的计算与威胁等级识别步骤如下：

① 确定一批监督目标的各类参数。

- 给出表 10.4 第  $j$  批目标（作为监督目标）的威胁级别为 4，即威胁级别监督向量为  $(f_{1j}, f_{2j}, \dots, f_{5j}) = (0.0, 0.0, 0.0, 1.0, 0.0)$ ；
- 根据表 10.4 中的数据，计算获得该监督目标的 5 阶威胁属性隶属度取值为  $(r_{1j}, r_{2j}, \dots, r_{5j}) = (0.86, 0.68, 1.00, 1.00, 0.80)$ ；
- 取监督因子  $\alpha = 0.5$ ，由式 (10.30) 计算得到该监督目标的 5 个 ( $c = 5$ ) 威胁级别关于各威胁属性的归一化矩阵

$$S = \left\{ (S_{ih})_{h=1}^5 \right\}_{i=1}^5 = \begin{matrix} & \begin{matrix} h=1 & 2 & 3 & 4 & 5 \end{matrix} \\ \begin{pmatrix} 0.11 & 0.31 & 0.55 & 0.72 & 0.92 \\ 0.13 & 0.34 & 0.62 & 0.76 & 0.95 \\ 0.26 & 0.53 & 0.63 & 0.85 & 0.98 \\ 0.19 & 0.43 & 0.68 & 0.84 & 0.95 \\ 0.22 & 0.36 & 0.61 & 0.74 & 0.92 \end{pmatrix} & \begin{matrix} i=1 \\ 2 \\ 3 \\ 4 \\ 5 \end{matrix} \end{matrix}$$

- 由式 (10.32) 计算得到该监督目标威胁属性分量权重  $W = (0.33, 0.26, 0.12, 0.15, 0.14)$ 。

② 建立半监督威胁等级模糊模式识别模型。

- 根据表 10.5 给出的数据，基于 10.3.2 节中的公式，可计算获得三批待威胁估计目标的 5 个威胁属性分量取值的归一化矩阵

$$R = \begin{pmatrix} 0.00 & 0.61 & 1.00 & 0.40 & 0.50 \\ 0.54 & 0.72 & 0.22 & 0.90 & 0.65 \\ 0.84 & 0.81 & 1.00 & 1.00 & 0.80 \end{pmatrix}^T$$

- 取监督因子  $\alpha = 0.5$ ，基于已获得的监督目标的各类参数和给出的识别结果及三批待估计目标的威胁分量隶属度矩阵  $R_{3 \times 5}$ ，建立式 (10.26)、式 (10.27) 的半监督威胁等级模糊模式识别模型。

③ 模型求解与分析。

对所建立的一批监督、三批估计的半监督威胁等级识别模型采用前文描述的迭代解法，可获得满足精度要求的三批待估计目标的威胁估计权重向量  $W$  和各批目标威胁等级的属性分量归一化矩阵  $S$ ，代入式 (10.31)，获得三批目标对 5 个威胁等级的相对隶属度矩阵为

$$U_{3 \times 5} = \begin{pmatrix} 0.26 & 0.37 & 0.19 & 0.11 & 0.06 \\ 0.04 & 0.10 & 0.54 & 0.24 & 0.08 \\ 0.01 & 0.02 & 0.07 & 0.42 & 0.48 \end{pmatrix}$$

按式 (10.20) 计算得到按分级最大隶属度原则下的三批待估计目标的威胁级别模糊均值为(2.31、3.22、4.34), 即三批目标威胁等级模糊模式识别结果为: 第一批目标 2 级, 第二批目标 3 级, 第三批目标 4 级。

威胁估计涉及对双方作战意图的评估, 是一个复杂的模糊推理问题, 与指挥员对作战态势的理解、作战条令/条例的运用, 以及智慧和经验相关。本节讨论的基于半监督模糊识别模式的威胁等级识别数学规划模型可随战场态势(目标状态)变化更新模型参数, 并将已有战例的识别结果作为未知目标威胁等级识别的监督项, 体现了指挥员的经验和智慧, 为威胁估计提供了一条值得探索的新途径。

### 10.3.3 基于决策树学习的目标威胁估计算法

#### 1. 决策树的基本概念

决策树是一种基于实例的归纳分类学习方法<sup>[18]</sup>, 需要从无序、无规律的大量实例中提炼出树形决策形式的分类规则, 也被称为基于树结构的预测模型。

##### ① 决策树的结构。

策树的结构示例如图 10.9 所示。

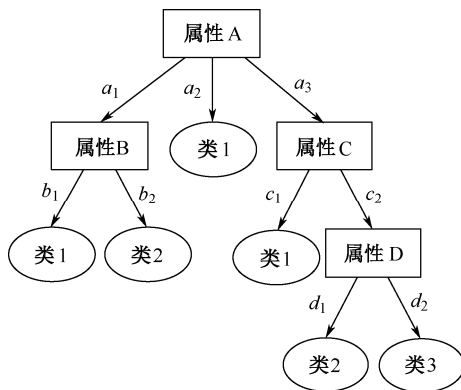


图 10.9 决策树的结构示例

在如图 10.9 所示描述的决策树结构示例中:

- 根节点表示决策起点;
- 分支节点表示一个数据集, 按上级节点的不同属性值分割产生;
- 叶节点表示一种分类结果;
- 分支有向边与出发节点判断结果对应, 产生到达节点的属性分割数据集的规则, 其中, 从根节点到叶节点的一条路径对应一条预测规则。

② 决策树功能包括归纳分类, 即 if—then 确定数据分类规则、基于分类规则预测关注对象, 并基于实际数据确定的分类规则进行因果分析、发现问题、改善规则。

③ 决策树的主要优势在于结构简单，易于理解；数据量不是很大，分类速度快；能处理连续、离散信息；能清楚显示重要信息。

## 2. 基于决策树的装甲目标威胁估计案例

装甲目标的威胁属性包括距离、打击能力、毁伤情况、运动状态、聚集状况等 5 个要素。

装甲目标威胁程度通常分为三级：最大威胁目标、中等威胁目标和较小威胁目标。

目标威胁估计用来确定威胁级别，以获得防卫方对目标打击的优先次序。

目标威胁估计的依据是目标各属性要素的时空威胁效用值和指挥员对装甲目标的威胁估计经验。

基于决策树的目标威胁估计规则生成框架如图 10.10 所示。

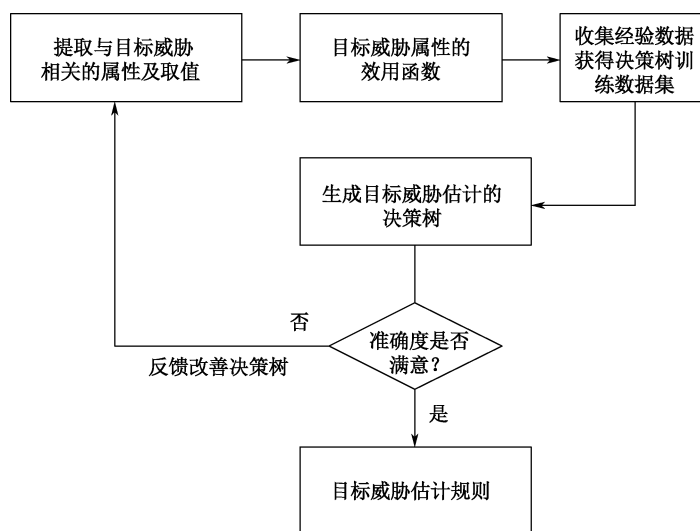


图 10.10 基于决策树的目标威胁估计规则生成框架

地面装甲目标对坦克威胁估计案例的基本流程如下：

### ① 目标威胁属性的提取。

提取装甲目标的威胁属性要素：目标与坦克的距离、目标是否具备攻击坦克的能力、目标自身被射击状况、目标运动状态及是否为集群目标等。

### ② 目标威胁属性要素的效用函数。

基于距离的威胁程度：大于 2500 m 为远距离，威胁程度较小；1500~2500 m 为中距离，威胁程度中等；小于 1500 m 为近距离，威胁程度最大。

基于打击能力的威胁程度：对坦克有打击能力的威胁最大；对坦克无打击能力的威胁较小。

基于被射击状态的威胁程度：装甲目标被射击未命中，威胁大；未被射击，威胁中；被射击命中，威胁小。

基于目标运动状态的威胁程度：静止或减速，威胁大（可能准备对坦克射击）；正常行进速度，威胁较小；行进速度快，威胁小。

基于聚集状态的威胁程度：集群目标，威胁大；单一目标，威胁小。

装甲目标对坦克威胁属性的效用见表 10.6。

表 10.6 装甲目标对坦克威胁属性的效用

威 胁 属 性	基 本 原 理	效 用
距离	1500 m 以内	大
	1500~2500 m	中
	2500~4000 m	小
打击能力	最近 30 s 内开过火	大
	正准备开火	中
	其他	小
被射击与命中情况	被射击未命中	大
	未被射击	中
	被射击且命中	小
目标运动状态	静止或减速	大
	正常速度	中
	加速	小
聚集情况	集群目标	大
	单个目标	小

③ 训练数据收集。

表 10.6 基于目标威胁属性的威胁程度判断共有 162 种情况，本例使用收集到的 120 组数据中的 100 组进行决策树训练，对余下的 20 组情况进行威胁判断验证。

④ 装甲目标对坦克威胁程度判断决策树如图 10.11 所示。

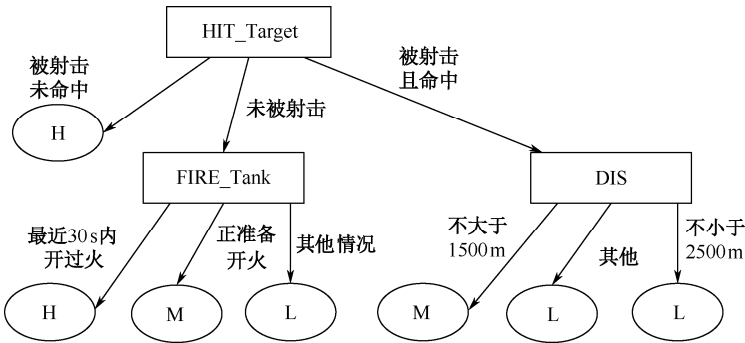


图 10.11 装甲目标对坦克威胁程度判断决策树

图中，HIT\_Target 根节点表示装甲目标被射击和命中的状况；FIRE\_Tankt 分支节点表示装甲目标对坦克的开火状态；DIS 分支节点表示装甲目标与坦克的距离。

⑤ 威胁程度估计结果分析。

装甲目标对坦克威胁程度的判断规则如下：

- 若目标被射击但未被命中，则威胁程度最大；
- 若目标未被射击过，且在最近 30 s 内开火过，则威胁程度最大；
- 若目标未被射击过，且正准备开火，则威胁程度中等；
- 若目标被射击且命中，距离较近（<1500 m），则威胁程度中等；
- 若目标被射击且命中，距离较远（>1500 m），则威胁程度较小。

其中,前三条是传统坦克分队战术规则,这里增添了最后两条规则,使目标威胁程度判断的正确率达到 85%,说明这里的 5 条规则较好地吸取了指挥员的实践经验。该方法的不足之处是难以充分获取训练数据。

## 10.4 多目标威胁估计方法

### 10.4.1 威胁函数与威胁值

多目标威胁多防卫对象的威胁估计更加复杂<sup>[19-24]</sup>。

(1) 目标—防卫对象配对 $(T_i, A_j)$ 及威胁度函数

目标—防卫对象配对及威胁度函数如图 10.12 所示。图中  $f(T_i, A_j) \in [0, 1] (T_i \in T, A_j \in A)$  为配对 $(T_i, A_j)$ 的威胁程度函数; 0 表示最小威胁, 1 表示最大威胁;  $T = \{T_1, T_2, \dots, T_n\}$  为能探测到的产生威胁的  $n$  个目标集合;  $A = \{A_1, A_2, \dots, A_m\}$  为  $m$  个防卫对象集合。




图 10.12 目标—防卫对象配对及威胁度函数

其中  $f(i, j) = f(T_i, A_j)$ 。  $f(T_i, A_j)$  可能基于配对中威胁目标的多属性(要素)产生, 包括相对距离、目标速度、海拔高度、武器覆盖范围、机动性能、火力及 IFF 模式等。由于可能不完整且受不确定性的影响, 因此产生了 10.3 节所述的各种威胁估计方法。

(2) 威胁值与综合威胁值

$V_{ij}$  表示目标—对象配对 $(T_i, A_j)$ 产生的威胁值;  $V_i$  表示目标  $T_i$  产生的综合威胁值, 表示目标  $T_i$  可能对多个防卫对象产生的威胁, 可由对配对产生的各单一威胁值  $V_{ij}$  综合产生:

$$V_i = \frac{\sum_{j=1}^m V_{ij} w_j}{\sum_{j=1}^m w_j} \quad i=1, 2, \dots, n, \quad j=1, 2, \dots, m \quad (10.42)$$

式中,  $w_j$  表示对象  $A_j$  的价值。

另一种计算方法如下:

$$V_i = \max_{1 \leq j \leq m} (V_{ij} w_j) \quad j=1, 2, \dots, m \quad (10.43)$$

显然, 威胁目标的综合威胁值  $V_i$  更重要, 按由大到小产生的优先级排序, 能够为判定对

多目标威胁的火力打击方案提供依据。因此,  $V_i$  是决定对目标打击优先排序的一个重要参数。

### 10.4.2 基于多价值准则的多目标威胁评估方法

从对威胁目标的拦截和火力打击的角度看, 要首先打击具有最大威胁的目标, 也就是具有最大价值的目标, 价值体现目标的重要程度及其对防卫对象的威胁程度。因此, 目标价值估计成为联合火力打击决策的关键问题。目标价值估计方法有直接估计法和间接估计法两种。

直接估计法: 从目标规模、性质、防护程度、打击难易程度等自然属性考虑目标的价值, 并通过建立完整的目标价值指标体系来估计目标价值。该方法估计的是目标的客观价值, 其应用价值在作战中对防卫对象产生的威胁特征并不显著, 并且在应用中, 由于不同类型、不同属性目标考虑的因素千差万别、错综复杂, 很难建立各类因素的统一价值指标体系, 无法统一度量不同属性因素, 特别是威胁属性因素与自然属性因素目标的价值。

间接估计法: 将目标价值分解为基于威胁属性的若干基本因素, 建立不同的估计准则, 从不同的角度对目标价值进行间接度量, 再通过合并算法将各基本因素的间接价值合成统一的目标价值函数, 从而解决不同属性目标价值的统一度量问题。

本节给出的多准则目标价值估计, 即基于该间接估计思想, 对目标的类别属性、分群属性及级别属性分别建立目标的类型价值准则、群价值准则和分级价值准则, 最后根据具体问题建立各准则估计价值的合并算法, 产生目标总价值。

#### 1. 基本模型

联合火力打击目标价值准则分解为类价值准则、群价值准则和级别价值准则, 分别表述如下:

类价值准则: 目标类型在联合火力打击中的效用, 由目标类型与打击任务的关联程度决定。在不同的任务中, 同一目标的类价值可能不同。

群价值准则: 战术目标群在联合火力打击中的效用, 是由联合火力打击任务中的打击重点、打击系统和打击方向等确定的。该目标群的重要性指数表示该目标群在打击任务体系中的重要程度, 是表示其所起作用大小的变量。

级别价值准则: 由目标在同一类目标或同一群目标中所处的层级关系所决定的, 该目标的相对重要性指数是类内或群内层次之间目标效用对比的结果。

目标  $x$  价值函数  $V(x)$  的多准则估计公式为

$$V(x) = V[f_L(x), f_Q(x), f_J(x)] \quad (10.44)$$

式中,  $f_L(x)$  为目标分类价值估计函数;  $L$  为目标分类集合, 与打击任务密切相关;  $f_Q(x)$  为目标集群价值的估计函数;  $Q$  为目标群集合;  $f_J(x)$  为目标级别价值的估计函数;  $J$  为目标分级集合。

显然, 式 (10.44) 表示的目标价值合成算法需要对目标进行合理的分类、分群及分级。基于联合作战理论的划分如下:

- ① 3 种目标分类: 军事类、政治类、经济类。
- ② 17 种目标分群: 按作战体系功能分为指挥机构、作战部队、通信中心等 17 个军用/



民用功能群。

③ 3 个目标分级：级别是在同一目标分类或同一目标集群中划分的。三级目标的概念如下：

- 一级目标：在目标类型或集群中处于较重要层次的目标。
- 二级目标：在目标类型或集群中相对较重要，处于中间层次的目标。
- 三级目标：在目标类型或集群中的重要程度不高，处于中下层次的目标。

## 2. 目标类价值函数

目标分类价值函数  $f_L(x)$  由打击任务  $L$  决定。全谱作战打击任务分为：军事打击任务，与军事类目标对应；政治打击任务，与政治类目标对应；经济打击任务，与经济类目标对应；综合打击任务，与不同权重的三类目标对应。

目标类型与任务的关联程度及相应的关联度见表 10.7。

表 10.7 目标类型与任务的关联程度及相应的关联度

关联程度	关联度 $d_x$
类型 $x$ 与任务 $L$ 对等关联（100%）	9
类型 $x$ 与任务 $L$ 确切关联（80%）	7
类型 $x$ 与任务 $L$ 一般关联（60%）	5
类型 $x$ 与任务 $L$ 模糊关联（40%）	3
类型 $x$ 与任务 $L$ 没有关联（40%以下）	1

目标类价值函数：

$$f_L(x) = k \times d_x \quad (10.45)$$

式中， $k$  为比例常数，由任务规模、打击范围、目标针对性确定；关联度  $d_x$  通常由类别  $x$  的目标在任务  $L$  中所占的比例来确定。对于综合打击任务而言，类别  $x$  的目标在任务中所占的比例为其分布在三种基本任务中所占比例之和。

所有类别为  $x$  的目标在某项任务  $L$  中所占总体比例  $l_x$  为

$$l_x = \sum_{i=0}^n l_{xi} \quad (10.46)$$

式中， $l_{xi}$  为第  $i$  个类别为  $x$  的目标在该项任务  $L$  中所占的比例，于是  $x$  类目标对三类任务的总关联度为

$$d_x = \frac{9l_x}{l_p + l_m + l_e} \quad (10.47)$$

式中， $l_p$ 、 $l_m$ 、 $l_e$  分别为  $x$  类目标在政治、军事及经济打击任务中所占的比例。

## 3. 目标群价值函数

目标群是战略或战役目标中具有相近部分战术功能的目标集合。群价值估计比类价值估计复杂，群价值不仅与目标群的功能、效用因素有关，还与其在任务中是否承担打击重点、主要攻击方向、系统打击任务等主要任务因素有关。因此，按层次分析法的思想，目标群价

值估计可以建立相应的价值估计矩阵, 表征各因素各水平的基本价值:

$$\mathbf{x}_q = \begin{bmatrix} q_{11} & \cdots & q_{1n} \\ \vdots & \vdots & \vdots \\ q_{m1} & \cdots & q_{mn} \end{bmatrix} = [\mathbf{h}_1, \mathbf{h}_2, \cdots, \mathbf{h}_n] \quad (10.48)$$

式中, 目标群  $x$  价值分为  $m$  级水平, 有  $n$  个依赖因素;  $q_{ij}$  表示目标群  $x$  依赖的  $j$  因素产生的  $i$  级价值指数;  $\mathbf{h}_i$  表示因素  $i$  的  $m$  级水平的价值指数向量。若  $\mathbf{h}_i$  对应的  $m$  级水平单位价值为  $l_i$ , 则目标群  $x$  的价值为

$$f_Q(x) = \sum_{i=1}^n \mathbf{h}_i^T l_i \quad (10.49)$$

对于不同功能的目标群而言, 构建统一的群价值指标体系比较复杂, 如空中飞机群、地面步兵群、电子战干扰群等。其攻击效能无法统一描述。价值体系与最终的作战效果相联系。这需从作战体系结构和功能入手, 分析各目标群作战效能的影响因素, 选取一致的、主要的因素构建群价值估计指标体系。

#### 4. 目标级别价值函数

级别价值与作战任务不相关, 只与目标在群内所处的位置层次、相互关系有关, 是群内目标重要性层次之间对比的结果。目标层级关系依赖的因素有目标规模、位置层次、影响程度、时空范围、发挥的作用等。由于目标层级能够直接、直观地表明相对重要性, 因此目标层级关系确定后, 比较容易计算目标级别价值。通常, 层级编号  $x$  的目标级别价值准则函数  $f_J(x)$  为

$$f_J(x) = k_l x^{-2} \quad (10.50)$$

式中, 反比例二次函数表示目标层级, 编号越小, 重要程度越高。目标级别一般分为三级: 即  $x=1, 2, 3$ , 相应的级别价值分别为  $k_l$ 、 $k_l/4$ 、 $k_l/9$ 。 $k_l$  为该目标在  $l$  群内的级别价值比例系数。

#### 5. 多准则目标价值的合成

##### (1) 多准则目标价值的合成准则

- 目标价值准则的递进关系。类价值准则是从目标能够遂行的打击任务类别及在其中产生的效能确定的, 是概略层面衡量的价值; 群价值准则是从目标遂行任务中的战术聚集层面产生的效能来衡量目标价值的; 级价值准则是从目标在类内或集群内所处重要性层次产生的效能来衡量目标价值的。
- 各价值函数值在目标合成价值中的重要程度是随时间和环境变化的, 随目标遂行的任务不同而不同, 随任务的变化而变化。
- 以对各价值函数值加权的形式度量目标的综合价值指数。

##### (2) 目标综合价值指数的加权和公式

$$V(x) = w_{L_x} f_L(x) + w_{Q_x} f_Q(x) + w_{J_x} f_J(x) \quad (10.51)$$

式中,  $w_{L_x}$ 、 $w_{Q_x}$  和  $w_{J_x}$  分别表示目标  $x$  类价值、群价值和级别价值在目标价值统一度量中

的权重系数。

### (3) 多准则价值合成方法的分析

- 该合成方法要求完整准确的目标分类、目标分群、目标分级的谱系信息；
  - 需要采用变权理论，使3个价值准则的权重能够随作战任务和环境的变化而变化。
- 这两点使该合成公式面临较大难度。

## 10.5 分布式环境中目标威胁估计的控制模式

### 10.5.1 分布式威胁估计的优势

威胁估计是指挥控制的一项关键功能。网络中心战(NCW)面临的挑战之一是不同作战力量必须通过信息共享达成一定程度的共用态势感知；在时间紧迫和大量不确定性条件下进行复杂的威胁判断，形成一致的(无冲突的)威胁列表，并基于该威胁列表协同遂行指挥控制与作战行动。在网络中心战中，各作战力量在陆、海、空、天、赛博各域分散部署的情况下，通过利用更多分散配置的信息源和计算能力，采用协同或联合方式进行威胁估计，能够大大减少不确定性，更能满足NCW指挥控制需求。分布式协同威胁估计具有4个方面的优势<sup>[25-29]</sup>。

① 功能分离：分布式威胁估计的对象是空间上分散的威胁实体，基于自身的能力和意图完成不同的任务。这种任务专业化的分割简化了威胁估计系统的设计，因为威胁估计功能被分配到各个实体，每个实体的威胁能力仅仅实现全部功能的一部分。

② 信息优势：分布式系统的主要优势是具有信息和资源的共享能力。不同信源提供的战场感知信息和知识经态势估计与威胁估计融合成一张共用作战图，增强了威胁估计的质量和対作战决策的支持能力。

③ 增强了实时响应：实时响应性是威胁估计的主要功能指标之一，通过把观察器和处理器分散配置在威胁对象附近可以达到这一目的。在一个网络化的环境中，这一点还具有直接改善指挥员实时指挥控制的潜力，并为指挥员提供快速评估不断变化态势的手段。

④ 稳健性和弹性：某些智能体(包括人员、软件和硬件)失效并不完全影响分布威胁估计的能力(只是部分影响)。也就是说，出现部分失效只能出现功能降级，而不是完全丧失威胁估计能力。如果分布式系统还有自组织能力，则还可以动态地重新组织各可用资源实现威胁实体的重新部署。这一特征使得该系统具有对部分智能体失效和偏差的高度容忍力。

### 10.5.2 分布式威胁估计的环境要求

在分布式威胁估计实现中，各估计智能体及其之间的交互要求具备下述环境条件：

① 互操作性：此项能力是指两个或多个分散配置的智能体、系统或其组成部分具有信息共享和功能交互的能力。分布式威胁估计可能涉及大量异类的个体和计算实体。它们在语言、背景、格式和内容上可能存在一定的差异。这增加了它们之间协作的困难。

② 连通性：通信关系的建立并非易事。在分布式威胁估计中，不同节点之间的远程连通是一项主要的技术挑战。信道很可能受到大量环境因素的干扰而导致质量降级。通信频率

的使用还面临需要避免受到敌方探测、定位和识别等隐蔽性的限制。

③ 安全性：威胁估计是一个特殊价值领域，其信息系统的安全性也受到挑战。尽管分布式信息源的使用可以改善分析人员的态势感知，但也使得系统更容易受到攻击、干扰、修改或摧毁。由于威胁估计的结果及作战方案的泄露是致命性的，因此威胁估计系统的安全性必须得到保证。

### 10.5.3 分布式威胁估计的协同模式

#### (1) 集中式态势标绘/集中式威胁估计

集中式态势标绘/集中式威胁估计模式如图 10.13 所示。

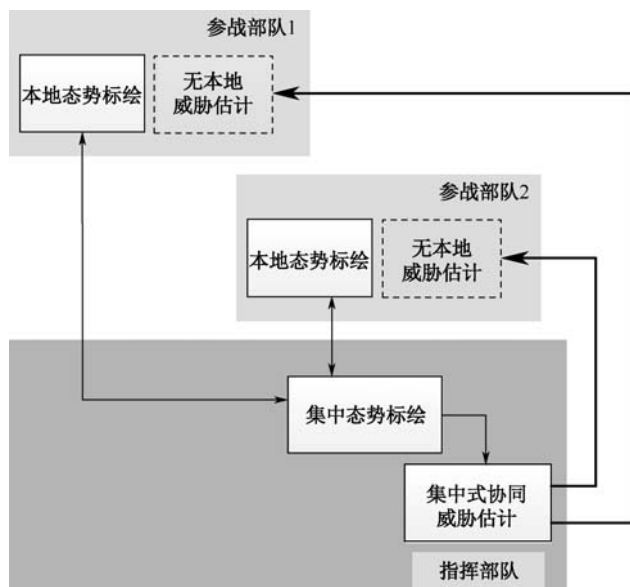


图 10.13 集中式态势标绘/集中式威胁估计模式

- 该模式下的各参战部队不进行威胁估计，采用指挥部队的集中式威胁估计结果。
- 该模式下的本地态势标绘结果要基于集中标绘结果进行画面更新，仅供本地指挥员观看。
- 该模式的通信负荷最重，要求各参战部队向指挥部队发送不断更新的局部战术图像或原始观测信息，以供指挥部队进行集中态势标绘和集中威胁估计。

#### (2) 分散式态势标绘/集中式威胁估计

分散式态势标绘/集中式威胁估计模式如图 10.14 所示。

- 该模式下的参战部队基于本地态势标绘进行本地威胁估计，但本地指挥员最终采用的是指挥部队下发的集中威胁估计结果。
- 各参战部队仅向指挥部队发送态势或目标的更新信息，以帮助指挥部队进行去冲突处理和集中态势标绘，支持集中式威胁估计，这比集中式态势标绘/集中式威胁估计发送的信息少多了，故通信负荷不重。



解。同样,各参战部队的威胁估计结果一致也是指对同一目标的威胁估计保持一致理解。

10.5.4 分布式协同威胁估计案例

这里的分布式协同威胁估计案例主要针对分散式态势标绘/分散式威胁估计模式中的信息请求和信息交换协同进行分析。多舰船协同防空威胁估计场景如图 10.16 所示。




图 10.16 多舰船协同防空威胁估计场景

图 10.16 包含 3 艘舰船 A、B、C 及 4 批对舰攻击空中目标 1001、1002、1003、1004。各舰船对空中目标的初始威胁估计结果见表 10.8。

表 10.8 各舰船对空中目标的初始威胁估计结果

航迹/舰船 A		B	C
1001	低	—	—
1002	中等	高	高
1003	—	中等	中等
1004	低	—	中等

在各舰船具有相同的场景视图（图 10.16）和相同的初始威胁估计结果（表 10.8）的条件下，舰船 B 在进行威胁估计协同时的信息请求与获取过程如下：

B 进行信息融合处理时，

- B 发现在战术图上并没有目标 1001 的航迹,而 A 生成目标 1001 的航迹并对其进行航迹延续;
- B 进一步发现其对目标 1002 的威胁估计（高）与 A 对 1002 的威胁估计（中等）冲突,在与 C 对 1002 的威胁估计没有冲突（皆为高）;
- B 对 1003 批目标的威胁估计与 C 对 1003 的威胁估计同为中等;
- 1004 批目标的航迹是 B 所缺乏的,且 A 与 C 对 1004 批目标的威胁估计是冲突的（低和中等）。

在上述情况下，

- B 向 A 请求目标 1001 的航迹信息，以弥补信息缺失；向 A 请求目标 1002 的航迹信息，以解决与 A 的威胁估计冲突问题。
- B 还向 A 和 C 请求目标 1004 的航迹信息，以解决 A 和 C 对目标 1004 航迹的威胁估计冲突问题。

综上所述，可得到以下结论：

这种分布式协同威胁估计模式要求各舰基于协同请求进行信息交换，交换的只是一小部分目标航迹或判断结论；

各舰要对与其他舰各局部威胁估计的冲突现象进行消解，这也只需要传输部分目标的威胁估计结论；

为了使各舰船平台对空中态势和威胁估计结果达到一致，这里的分散式态势标绘/分散式威胁估计模式产生的传输信息量较分散式态势标绘/集中式威胁估计和集中式态势标绘/集中式威胁估计两种协同工作模式传输的信息量更少，通信负荷最小。最坏的情况是各舰之间没有任何共用航迹，此时要求传输所有目标航迹的更新信息，产生与分散式态势标绘/集中式威胁估计模式同样的通信负荷。

## 10.6 通信状态对分布式威胁估计的影响

### 10.6.1 通信中断状态产生的影响

在联合作战中，某些参战部队可能会出现通信中断的情况，主要由硬/软件故障、毁损或电力供给中断及对手的电子干扰行动所致<sup>[30-33]</sup>。

通信中断状态对分布式威胁估计的影响取决于所采取的协同威胁估计的模式和通信中断部队的地位。

① 在集中式态势标绘/集中式威胁估计模式和分散式态势标绘/集中式威胁估计模式下，非指挥部队通信中断不影响其余部队系统正常的运行能力，但会影响威胁估计的质量，因为虽然指挥部队接收的信息减少了，但整个系统还是能够正常运行的。此时，若指挥部队通信中断，则整个协同威胁估计的机制失效，可能采取的恢复方法有两种：一种是将系统切换到分散式态势标绘/分散式威胁估计模式，直到通信恢复后再切换回原模式；另一种是将指挥部队的协同责任转移到另一个参战部队单元。为此，各个参战单元应有一个共用次序列表，一旦指挥部队通信中断，就自动实现责任/角色切换。

② 在分散式态势标绘/分散式威胁估计模式下，如果一个参战部队单元通信中断，则其他参战部队将接收不到向该单元请求的回答信息，但仍能接收到向其他单元请求的回答信息，如在 10.5.4 节的案例中，A 向 B 请求目标 1003 的航迹信息，与 B 通信中断了，A 将接收不到 B 的目标 1003 的航迹信息，但 A 可向 C 请求，接收 C 发送的目标 1003 的航迹信息。

解决这一问题的方法是，当一个参战部队出现通信中断时，所有的参战部队应通播其目

标航迹和威胁估计结果。

③ 若参与联合作战任务的某一参战部队与所有其他单元的通信都中断了，则只能依靠自身的情报信息进行局部态势标绘并进行局部威胁估计，遂行局部作战任务。

10.6.2 通信降级状态产生的影响

通信降级是指网络提供的通信能力（带宽）减少，通常是由连接节点（参战单元）太多或目标太多引起的。为维持威胁估计的实时性，尽量减少通信量是一项有效的措施，能够使网络支持其请求并接收信息传输而不会产生太大的延迟。

从 10.5.3 节对态势标绘/威胁估计 3 种协同模式的传输信息量分析，基于网络带宽的可用性，选取合适的协同威胁估计模式十分重要，如图 10.17 所示。

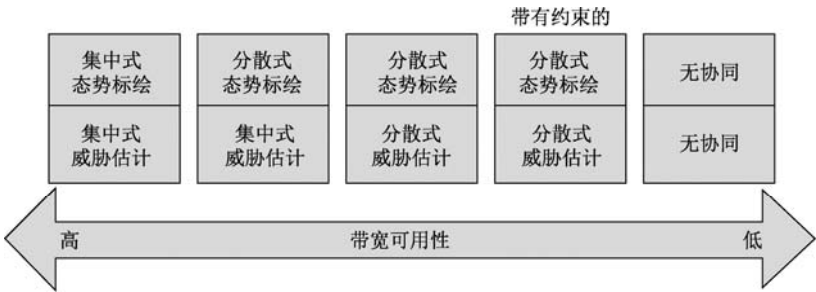


图 10.17 协同威胁估计模式与带宽可用性的关系

从图 10.17 中可以看出，分布式协同威胁估计模式的选择可从网络带宽最高可用性支持的集中式态势标绘/集中式威胁估计模式出发，随网络带宽可用性的降低逐步向以下诸模式转移，直到无通信带宽支撑的无协同模式。

参考文献

[1] 赵宗贵, 熊朝华, 王珂, 等. 信息融合概念、方法与应用[M]. 北京: 国防工业出版社, 2012, 145-200.

[2] 熊朝华,刁联旺. 多维视角下的目标威胁估计[C]. 第六届中国信息融合大会, 南京, 2014, 5-10.

[3] J J Salerno. Where's level 2/3 fusion: A look back over the past 10 years[C]. Proceedings of the Tenth International Conference on Information Fusion, Quebec, 2007.

[4] B McGuinness, L Foy. A subjective measure of SA: The Crew Awareness Rating Scale(CARS)[C]. Proceedings of the First Human Performance: Situation Awareness and Automation Conference, Savannah, GA, October, 2000.

[5] Martin E Liggins, David L Hall, James Llinas. Handbook of Multisensor Data Fusion: Theory and practice (2nd), Chapter 18 Foundation of Situation and Thread Assessment[M]. CRC Press, Taylor & Francis Group, Boca Raton, London, New York, 2008.

[6] T S Levitt, C L Winter, C J Turner, et al. Bayesian inference-based fusion of radar imagery, military forces and tactical terrain models in the image exploitation system/balanced technology initiative[J]. IEEE



- International Journal on Human-Computer Studies, 1995, vol42, 667-686.
- [7] K B Laskey, S Stanford, B Stibo. Probabilistic Reasoning for Assessment of Enemy Intentions[D]. George Mason University, 1994.
- [8] 冯卉, 邢清华, 宋乃华. 一种基于区间数的空中目标威胁评估技术[J]. 系统工程与电子技术, 2006, 28(8): 1201-1204.
- [9] 曹可劲, 江汉, 赵宗贵. 一种基于变权理论的空中目标威胁估计方法[J]. 解放军理工大学学报(自然科学版), 2006, 7(1): 32-36.
- [10] 高晶, 李为民. 完全权重信息下目标威胁模糊评估[J]. 战术导弹技术, 2006(1): 64-67.
- [11] 程红斌, 张晓丰, 张凤鸣. 基于模糊层次分析法的威胁估计[J]. 现代雷达, 2006, 28(3): 2-24.
- [12] 刘军, 贾宏慧. 部分指标值未知的空中目标威胁评估模型[J]. 计算机工程与设计, 2006, 27(21): 4115-4118.
- [13] 黄宪成, 陈守煜. 定量和定性指标相混合的威胁排序模型[J]. 兵工学报, 2003, 24(1): 78-82.
- [14] 范春彦, 韩晓明, 王献峰. 基于最大隶属度的目标威胁评估与排序法[J]. 系统工程与电子技术, 2003, 25(1): 47-50.
- [15] Haixin Zhang, Bingyi Kang, Ya Li, et al Target Threat Assessment Based on Interval Data Fusion. Journal of Computational Information Systems, 2012, 8: 6 2609-2616.
- [16] 潘红华, 王建国, 朱森, 等. 目标威胁判断的模糊模式识别模型[J]. 兵工学报, 2004, 25(5): 576-580.
- [17] 唐焕文. 实用数学规划导论[M]. 大连: 大连理工大学出版社, 1986.
- [18] 刁联旺, 于永生. 目标威胁估计的决策树方法[J]. 江南大学学报(自然科学版), 2009, 8(5): 513-516.
- [19] 王改革. 基于智能算法的目标威胁估计[D]. 中国科学院研究生院, 2013.
- [20] 郝兴国, 张安, 汤志荔. 空战威胁估计系统建模仿真研究[J]. 现代电子技术, 2011, 34(2): 46-70.
- [21] 余舟毅, 陈宗基, 周锐. 基于贝叶斯网络的威胁等级评估算法研究[J]. 系统仿真学报, 2005, 17(3): 555-558.
- [22] 赵建军, 王毅. 基于动态贝叶斯网络的防空作战威胁估计[J]. 计算机技术与发展, 2012, 22(11): 138-144.
- [23] F Johansson, G Falkman. A Bayesian network approach to threat evaluation with application to an air defense scenario[C]. 11th International Conference on Information Fusion, 2008.
- [24] J N Roux, J H Van Vuuren. Threat evaluation and weapon assignment decision support: A review of the state of the art, Orion[C]. 2007, vol. 23, 151-186.
- [25] S Paradis, A Benaskeur, M Oxenham, et al. Threat evaluation and weapons allocation in network-centric warfare[C]. In: Proceedings of the 8th International Conference on Information Fusion, 2005.
- [26] F Johansson. Evaluating the performance of TEWA Sys-tem[D]. Orebro University, 2010.
- [27] Y Liang. A fuzzy knowledge based system in situation and threat assessment[J] Journal of Systems Science & Information, 2006, 4, 791-802.
- [28] M Liebhauer, B Feher. Air threat assessment: Research, model, and display guidelines[C]. in Proceedings of the Command and Control Research and Technology Symposium, 2002.
- [29] Y Liang. An approximate reasoning model for situation and threat assessment[C]. in Proceedings of the 4th

International Conference on Fuzzy Systems and Knowledge Discovery, 2007.

- [30] Johansson R, G Falkman.. A Bayesian network approach to threat evaluation with application to an air defense scenario[C]. Proceedings of Fusion 2008, Cologne, Germany, 2008, 1–7.
- [31] Roy J.. A view on threat analysis concepts[C]. Technical report, Valcartier, Valcartier Quebec, Canada, 2009.
- [32] Paradis S, A Benaskeur, M Oxenham, et al. Threat evaluation and weapons allocation in network-centric warfare[C]. Proceedings of Fusion 2005, Philadelphia, PA, 2005.
- [33] S Kumar, A M Dixit. Threat Evaluation Modelling for Dynamic Targets Using Fuzzy Logic Approach[C]. International Conference on Computer Science and Engineering, 2012.

# 第 11 章 分布式传感器管理

随着传感器探测能力的提高,现在的传感器探测系统往往由多个本身功能就已经十分强大的单一传感器组成。该传感器系统不仅构成了多传感器互补体系,而且能够通过适当地管理这些传感器获得最优的目标数据获取能力。这些能力包括目标探测和跟踪、搜索范围和扫描控制、目标发现指示和探测交接控制等<sup>[1,2]</sup>。运行在多目标环境的传感器系统还要按目标威胁程度、截获时机等进行传感器探测需求排序,以实现传感器对探测目标的优化分配。本章将重点讨论基于优化算法的多传感器管理方法,主要包括基于模糊推理的传感器管理算法,以及在数学规划支持下的基于效用函数和基于市场拍卖理论的传感器管理方法<sup>[3]</sup>。

## 11.1 概述

多源传感器数据融合是 20 世纪 70 年代伴随着计算机技术、信号检测与处理技术及传感器技术发展而迅速兴起的一门多学科交叉应用技术。它通过对多传感器获得的信息进行选择、滤波、互补等综合处理来提高感知系统的效能。在多目标环境中,由于传感器资源是有限的,从而对多传感器进行管理成为提升多传感器数据融合系统效能的关键。因此,传感器管理成为信息融合学科中一项极其重要的研究内容,对传感器管理方法进行研究具有十分重要的理论意义和应用价值。

### 11.1.1 传感器管理的概念

传感器管理是利用有限的传感器资源,以满足多目标探测需求获得各目标状态和属性参数的最优估计为准则,对传感器资源进行合理的探测分配<sup>[4-6]</sup>。简而言之,传感器管理的核心问题就是依据一定的最优准则建立一个易于量化的指标函数,通过优化该指标函数来选择传感器及其工作方式或参数。传感器管理作为数据融合系统的反馈控制环节,使数据融合系统构成一个闭环控制系统,从而提高系统的实时性和整体优化水平<sup>[7-10]</sup>,如图 11.1 所示。




图 11.1 基于传感器管理的数据融合闭环控制模式

传感器管理的首要目标是有效选择和配置可使用的传感器资源来获取相关的目标信息,包括传感器部署管理和传感器探测控制,以便有效地完成感知任务。在多传感器数据融合系

统的融合性能评估中,可以用来指导传感器资源分配的参数有很多,最为常见的卡尔曼滤波误差协方差矩阵(或信息矩阵)就是跟踪系统性能的主要度量指标之一。因此,可以利用卡尔曼滤波的误差控制传感器资源的分配。传感器管理的另一个目标是实现感知系统的整体优化。在图 11.1 中,通过检查跟踪效果与具体感知需求之间的差异产生一个反馈控制,从而对已配置传感器的运行状态进行控制。当多个传感器同时用于多目标探测时,必须解决传感器目标探测的分配及检测、定位跟踪和识别之间的资源调度问题,也就是在一定条件下,如向合理利用传感器探测资源和信息融合处理资源以达到满足战场感知需求的系统最优感知性能,如图 11.2 所示。




图 11.2 战场感知资源管理的闭环控制模式

### 11.1.2 传感器管理的内涵和效用

传感器管理主要包括空间管理、模式管理和时间管理,由作战系统应用需求、目标价值、战场态势估计、作战事件的优先级等众多因素驱动<sup>[4,5]</sup>。

① 空间管理:对非全向传感器给出其空间观测方向。对监视应用来说,传感器的视野必须有规律地移动(扫描),以搜索和截获新的目标或周期性地再现目标点,以获得运动目标的航迹。

② 模式管理:对传感器进行工作模式的选择,包括对传感器的孔径、搜索模式、信号波形、功率级别及处理技术的选择,如机载火控雷达一般有主动、被动、低截获概率等多种工作模式。

③ 时间管理:在传感器必须与其他传感器或目标环境中的事件同步运行的情况下(如目标检测、航迹丢失、对抗活动),要求对传感器的操作进行定时管理。

传感器管理的目的是减轻操作者的工作负荷、优化配置传感器资源及对环境变化具有更快速的自适应性。

① 减轻操作者的工作负荷:操作者的人工操作是传感器系统的必要因素,由于操作者通常需要及时制定传感器调度和任务目标等高级别的策略,因此不应当被低级别的非战术决策分散其对主要任务目标的注意力。有了传感器管理系统,操作者只需建立传感器的总体任务目标,传感器管理系统就会自行对传感器低级别的功能加以控制。这样,大量传感器的具体细节信息就不必呈现给操作者了。

② 优化配置传感器资源:传感器管理系统能根据系统需求和目标环境自动优化配置传感器资源,增强系统的探测能力、时空覆盖范围及覆盖率,最大限度地降低目标环境的不确定性,使各种约束条件下的系统融合感知性能达到最优。

③ 具有更快的战场环境适应性：具有传感器管理的自反馈系统能够对变化的环境产生更快的响应和适应性。因为传感器管理系统能够基于传感器状态的细节提取出传感器工作性能信息，因而能够早期预测传感器探测性能的变化趋势，进而基于变化的战场态势感知需求对探测资源加以调控和优化分配。

### 11.1.3 传感器管理的功能

#### 1. 传感器工作模式

传感器的探测能力和运行模式是实现传感器的管理基础。通常，传感器的设计有 5 类运行模式：①固定类模式，基于探测周期获得探测对象的当前状态（位置和速度等）和属性；②事件类模式，提供对象状态变化（发现、消失、机动或属性变化）的事件通知或告警；③触发类模式，只有当对象状态变化等事件出现时才提供对象状态，即前两类模式的结合；④动向类模式，传感器记录一段时间的检测数据并生成统计结果，称为对象动向感知；⑤偏移类模式，检查动向统计结果超过预设门限的情况，用来指示态势是否正向一个不希望的状态变化，如可能产生一个威胁。传感器的 5 类运行模式在功能上是递进的，是将其探测能力与录取软件相结合实现的。

#### 2. 传感器管理功能的内涵

基于传感器 5 类运行模式的传感器管理功能<sup>[4,5]</sup>主要包括：

① 目标排序：必须确定传感器探测系统所探测目标（和可能的搜索空间）的重要等级，即相对优先级，以建立一个多指标的数学规划模型，由此确定传感器资源优化分配方案。决定目标优先级的因素包括人为指定的优先级、当前目标状态（来自航迹文件）及未来目标状态（来自数据融合中的态势估计）。因为基于这些信息能够预测未来可能出现的威胁或事件。按优先级进行的目标排序是对目标进行传感器资源分配的一项重要指标。

② 事件预测：基于当前事件、目标状态和战术原则/条例知识，预测未来可能发生的事件，通过管理和控制传感器来检测或验证所期望的事件，如在目标跟踪中，根据对目标位置的预测，引导传感器不间断地跟踪目标。

③ 传感器探测效能预测：为产生传感器分配的可选方案，必须事先确定传感器对目标的探测效能。任一传感器分配给一个目标的探测效能可以用一个配对的有效性度量。传感器的性能模型可用来预测传感器对配对目标的探测效能，以量化表示各可选传感器分配的效用。

④ 传感器对目标的分配：当出现多目标和多传感器的情况时，传感器管理能够产生一个多传感器对多目标的分配方案。该分配方案通常基于某些综合指标函数的优化处理产生。这些指标函数是多传感器对所有配对目标的综合探测效能的一种度量。当然，指标函数应该是目标优先级和传感器对配对目标探测的效能函数。

⑤ 空间和时间范围控制：必须基于探测目标的位置设置传感器的视域，通过管理一组传感器的监视空间范围始终覆盖探测的目标（进行航迹更新），并搜索进入该组传感器监视空间的尚未探测到的新目标。传感器搜索空间范围控制和持续照射被跟踪目标所花费的时间

总量控制需要考虑检测概率（新目标）、跟踪和识别性能（已建立航迹的目标）及我方探测平台被敌方传感器探测和跟踪概率的因素。这种搜索空间范围和持续跟踪目标的时间控制功能是任务模式、操作员决策和目标状态的函数。

⑥ 运行和控制策略：传感器运行要求将传感器分配问题的求解方案转换成对传感器的命令，同时包含一些附加的控制要素。例如，反对抗措施，通过控制传感器的频段、空间和时间进行传感器管理，使对敌人干扰措施（电磁干扰、欺骗和伪装）的对抗性能达到最优；目标指示和交接，当需要将传感器 A 指向、搜索并截获原来由另一传感器 B 跟踪的目标时，必须向传感器 A 发出一个空间搜索指令，该指令必须定义搜索模式、脉冲间隔、目标方位/距离及标识等必要参数；操作时序表，对传感器模式、探测指向、主动运行等有效操作要按时序对具体的传感器进行控制。

⑦ 传感器系统感知质量控制：传感器管理要保证传感器系统感知功能的完整性和应用的可靠性。传感器管理要定时检验系统探测目标的缺失（漏警）率、假目标（虚警或冗余目标）率、覆盖率及目标连续跟踪率，并定时检验和保持目标跟踪误差使识别率满足应用需求。

通过完成上述功能，传感器管理可预测未来可能发生的事件，并依据传感器对不同目标的实际检测效能，在一定的准则下，指派传感器探测不同的目标，覆盖预定空域和目标，并完成对传感器的指令，指引传感器运行操作。

可见，传感器管理的研究内容十分丰富和复杂。本章主要介绍采用最优化数学方法进行传感器管理的一些技术途径，即基于效用函数的、基于模糊推理的及基于拍卖理论的传感器管理方法，以探索目标探测跟踪领域中传感器管理的优化策略。

## 11.2 基于效用函数的目标探测传感器资源管理算法

对于多目标环境中运行的多传感器系统，自然要考虑多传感器对多目标的探测分配问题<sup>[4,5]</sup>。当在传感器的观测范围内监测的目标数量较少时，传感器的分配问题并不复杂，一种比较简单的传感器分配方法是：用一个传感器去引导其他传感器，如用一种分辨率较低但监测范围很大的传感器进行大范围内的快速搜索，获得目标位置的粗略估计，然后引导高分辨的传感器转向该目标粗略估计的位置进一步进行高精度的测量。但是当环境中需要探测的目标数量较多，传感器资源相对有限时，问题就不那么简单了。这种情况的处理一般有两种可选方案。一种是采用时间片轮换法，即按一定的时间周期，轮流更新所有目标的航迹文件。这种方法有很明显的缺点：无法控制目标跟踪精度和连续性，并且在跟踪切换时开销过大。另一种方法是根据分配模型建立某种目标分配效能指标，通过使该指标值达到最大确定最优分配方案。一个合理的传感器分配方案应该使多传感器系统的综合探测效能达到最优，具体来说，当把  $m$  个传感器分配给  $n$  个探测目标时，要求所有传感器的合成探测区域应覆盖所有的目标并且对任一目标的漏检率最小。影响传感器系统整体效用的因素包括：

① 传感器系统覆盖空间的大小。每个传感器对搜索区域的扫描周期对应着目标复现率，整体效用要求以传感器最少检测次数或动用最少的传感器资源或延续已有目标航迹探测到新目标。

② 传感器对目标航迹估计的连续性及其估计的精度。

③ 传感器的安全性。有源传感器发射的信号可能会被敌方传感器发现，保证我方传感器具有低被发现概率有时也成为传感器控制需要考虑的因素之一。

基于效用的多传感器多目标分配算法是把传感器对跟踪目标的效用值作为优化指标，采用使用多传感器效用值最高的传感器分配方案对目标实施跟踪。以效用为分配准则的求解模型包含以下 3 部分：

- ① 定义一个适当的指标函数。该指标函数要能描述每个互不相容的传感器分配方案产生的效用（价值）。
- ② 定义传感器分配的约束条件，包括传感器的探测能力约束和满足任务应用需求约束。
- ③ 考虑实际情况下的有限传感器资源约束。

### 11.2.1 问题描述

在信息化战争中，导弹与飞机具有较大的作用，作战双方一般都采用多传感器按预设方案探测和监视空天目标，并将探测数据发送给信息融合中心，同时将融合中心的数据处理结果反馈给传感器管理系统，用来指导各传感器的优化分配。这必然导致在探测过程中多传感器对多目标的动态分配问题。实际上，传感器与目标的分配关系不是一对一的，有可能一个目标由多个传感器联合探测，也有可能一个传感器被分配探测多个目标，还有可能有传感器没有被分配去探测任何目标。为了应对这种目标——传感器非唯一分配的情形，对以上问题进行转化，定义“虚拟传感器”表示用于探测一个目标的多传感器组合，用“基本传感器”表示真实的单一传感器；每个“传感器”组合至少有两个传感器；基本传感器与虚拟传感器不能重复使用。其数学模型可以简化描述如下：

- ① 对给定的基本传感器  $s_i$ ，其监视能力，即最多监视的目标数为  $c_i$ （ $i=1, 2, \dots, m$ ），因此它们的总体监视能力（记为 TC）可表示为  $TC = \sum_{i=1}^m c_i$ 。
- ② 对于  $m$  个基本传感器  $s_i$ ，其可能的组合总数（记为  $M$ ）为  $M = 2^m - 1$ 。
- ③ 共有  $n$  个待监视的目标，记为  $o_j$ （ $j=1, 2, \dots, n$ ）。
- ④ 传感器（包括虚拟传感器与基本传感器） $s_i$ （此时  $i=1, 2, \dots, M$ ）对目标  $o_j$  的分配关系用决策变量  $x_{ij}$ （ $x_{ij} = 0$  或  $1$ ， $0$  表示不分配， $1$  表示分配）表示，可获得传感器—目标分配矩阵，记为  $\mathbf{X} = (x_{ij})_{M \times n}$ ，见表 11.1。

表 11.1 传感器—目标分配矩阵

传 感 器		多 目 标			
		1	2	...	$n$
基本传感器	1	$x_{1,1}$	$x_{1,2}$	...	$x_{1,n}$
	2	$x_{2,1}$	$x_{2,2}$	...	$x_{2,n}$
	...		...	...	...
	$m$	$x_{m,1}$	$x_{m,2}$	...	$x_{m,n}$
虚拟传感器	$m+1$	$x_{m+1,1}$	$x_{m+1,2}$	...	$x_{m+1,n}$
	...	...	...	...	...
	$M$	$x_{M,1}$	$x_{M+1,2}$	...	$x_{M,n}$

可见,多传感器多目标的合理分配问题就是在满足多传感器系统的约束条件下使效用指标函数达到极大,求解确定传感器分配矩阵  $X = (x_{ij})_{M \times n}$  中各元素的具体取值,将多目标合理地分配给多个传感器(基本传感器和虚拟传感器)。

### 11.2.2 基于效用的传感器资源分配数学模型

假定在防空作战中防空部队面对多个空中目标,要对所拥有的探测资源(如雷达)进行合理分配,以充分发挥多传感器探测系统的最大效用。

影响传感器对目标的探测效用主要有两个方面:一是目标的威胁程度,目标的威胁程度越大,传感器监视(跟踪)目标的效用越高,目标探测优先级也越高;二是传感器对目标的配对指数,目标的特性不一,如有些机动能力强、速度慢,有些速度快、机动能力差。可见,传感器与目标配对的侧重点不同,造成对目标的探测效果也不一样。

记目标优先级为  $q_j(o_1, o_2, \dots, o_n)$ ; 传感器—目标配对指数为  $p_{ij}(s_1, s_2, \dots, s_M; o_1, o_2, \dots, o_n)$ ; 定义传感器(基本的或虚拟的)  $s_i$  与目标  $o_j$  监视(跟踪)配对的效用函数为

$$g_{ij}(s_1, s_2, \dots, s_M; o_1, o_2, \dots, o_n) = q_j(o_1, o_2, \dots, o_n) \times p_{ij}(s_1, s_2, \dots, s_M; o_1, o_2, \dots, o_n) \quad (11.1)$$

式中,  $i=1, 2, \dots, M$ ;  $j=1, 2, \dots, n$ 。式(11.1)中右边第一项是目标优先级;右边第二项为传感器—目标配对指数,代表传感器对目标的探测能力。一个传感器对某种特定目标的探测能力越强,则对该种目标的效用越高。两者与系统的效用都为线性正比关系,用目标威胁度与配对指数的乘积来定义效用。

传感器分配的指标函数是综合效用

$$G = \sum_{i=1}^M \sum_{j=1}^{n+1} [x_{ij} g_{ij}(s_1, s_2, \dots, s_M; o_1, o_2, \dots, o_n)] \quad (11.2)$$

使该指标函数达到最大值的传感器分配矩阵  $X = (x_{ij})_{M \times (n+1)}$  就是最优的多传感器—多目标分配方案。这里定义了一个虚拟目标  $n+1$ , 因为当传感器系统能力过剩时,应当允许有传感器处于空闲状态,将其称为分配给一个虚拟目标。

对于传感器探测能力来说,一个传感器(基本的和虚拟的)可以探测的目标个数受能力限制。对于基本的传感器,其能力就是该单一传感器的最大目标跟踪能力;对虚拟的(组合)传感器,根据木桶原理设定,即虚拟传感器的最大探测目标个数由传感器组合中某个探测目标数目最小的基本传感器决定。

对于探测范围来说,一个目标可以被多个传感器探测,但至少必须被一个传感器探测,即不能漏警。因此,传感器分配解矩阵  $X = (x_{ij})_{M \times (n+1)}$  应满足以下约束条件。

约束条件 1: 传感器跟踪能力约束,即

$$\begin{cases} \sum_{j=1}^n x_{ij} \leq c_i, x_{i,n+1} = 0 \\ \sum_{j=1}^n x_{ij} = 0, x_{i,n+1} = 1 \end{cases} \quad i=1, 2, \dots, M \quad (11.3)$$

式中,第二式表示传感器  $s_i$  处于空闲状态。



约束条件 2：传感器对目标覆盖约束，即

$$\begin{cases} \sum_{i=1}^M x_{ij} = 1 & j=1, 2, \dots, n \\ \sum_{i=1}^M x_{ij} \geq 0 & j=n+1 \end{cases} \quad (11.4)$$

式 (11.4) 表示传感器系统对目标的探测覆盖率为 1。其中，第二式表示对虚拟目标可以覆盖，也可以不覆盖。通过分析该约束条件及前面提到的分配矩阵，带约束的传感器分配矩阵表见表 11.2。

表11.2 带约束的传感器分配矩阵表

	1	2	...	$n$	$n+1$	传感器能力约束
1	$x_{1,1}$	$x_{1,2}$	...	$x_{1,n}$	0/1	$c_1/0$
2	$x_{2,1}$	$x_{2,2}$	...	$x_{2,n}$	0/1	$c_2/0$
...		...	...	...	...	...
$m$	$x_{m,1}$	$x_{m,2}$	...	$x_{m,n}$	0/1	$c_m/0$
$m+1$	$x_{m+1,1}$	$x_{m+1,2}$	...	$x_{m+1,n}$	0/1	$c_{m+1}/0$
...	...	...	...	...	...	...
$M$	$x_{M,1}$	$x_{M,2}$	...	$x_{M,n}$	0/1	$C_M/0$
目标覆盖约束	1	1	...	1	0/1	

可见，多传感器多目标分配问题被抽象成一个典型的带有约束条件的数学规划问题。该问题模型提出的效用度量在一定意义下满足分配指标函数的约束条件。虽然如此，该模型还是对实际问题做了简化。比如，对于传感器的最大跟踪能力约束模型，由于传感器跟踪能力体现在扫描探测模式、位置状态估计等诸多方面，因此这里仅以可跟踪目标数量表示传感器能力。下面讨论目标优先级和传感器—目标配对指数的确定问题。

### 1. 确定目标优先级

就多传感器资源分配而言，传感器与目标的有效配对是关键因素，而目标优先级是有效配对的基础。目标优先级涉及目标自身的重要程度、目标的威胁程度及防卫方对目标实施拦截或打击的信息在作战中的需求程度等诸多方面<sup>[18,19]</sup>。

目标的重要程度（记为 TIM）可以用目标价值系数进行定量计算，而目标价值系数由目标的军事价值系数、政治价值系数、经济价值系数及心理价值系数等诸多指标综合确定。对于传感器管理，重点关注的是目标军事价值，即目标对作战能力的贡献，一旦目标被毁，所引起的敌方作战能力的下降值能够反映该目标在军事上的重要性。一个目标的军事价值越大，该目标在军事系统中的地位越重要。目标的军事价值主要由直接作战能力系数（表示目标在作战中对我军火力压制、摧毁和拦阻的能力，记为 DMV）、间接支援作战能力系数（表示目标在作战中提供后勤保障的能力，记为 SMV）和潜在支援作战能力系数（表示目标间接提供作战经济和物质保障的能力，记为 PMV）构成，于是得到目标重要程度为

$$\text{TIM} = \lambda_1 \times \text{DMV} + \lambda_2 \times \text{SMV} + \lambda_3 \times \text{PMV} \quad (11.5)$$

式中， $\lambda_1$ 、 $\lambda_2$  和  $\lambda_3$  分别为目标的直接作战能力、间接支援作战能力和潜在作战能力系数的权

重,可以根据专家经验确定。其中,直接作战能力最重要,间接支援作战能力次之,潜在作战能力的权重最小<sup>[11]</sup>,通常取值分别为 0.4、0.35 和 0.25。对不同的威胁目标,DMV、SMV 和 PMV 的计算方法有很多,可以参考文献[12-14],这里为了进行综合评价,需要进行归一化处理。

防卫方对目标信息的作战需求(记为 TIR)需要附加传感器信息以检测、提取、更新目标的位置,这是建立目标优先级的另一个因素。附加传感器信息能够解决目标状态的模糊性,改进测量精度或更新动态目标数据。这里采用文献[1]提出的目标航迹质量评估方法进行评价,即求取目标航迹误差半径  $r$ ,与目标跟踪所需要的航迹误差半径  $r_0$  进行比较,以确定对目标信息的需求满足程度 TIR,计算公式为

$$\text{TIR} = \begin{cases} r_0 / r & r > r_0 \\ 1 & r \leq r_0 \end{cases} \quad (11.6)$$

目标的威胁程度(TTR)参考本书第 10 章的相关内容,这里为了进行综合评价,也需要进行归一化处理。

令  $q_j$  表示目标  $j$  的优先级评价值,应用常用的线性加权方法,目标优先级函数可表示为

$$q_j = W_1 \times \text{TIM} + W_2 \times \text{TIR} + W_3 \times \text{TTR} \quad (11.7)$$

式中,  $W_1$ 、 $W_2$ 、 $W_3$  分别表示目标重要程度、目标信息满足应用需求程度及目标威胁程度的权重系数。由于目标重要程度和威胁程度是作战更为关心的要素,因此可取它们的权重分别为 0.4、0.2 和 0.4<sup>[15]</sup>。

## 2. 确定传感器—目标配对指数

如前所述,多传感器多目标分配的目的是实现多传感器探测系统的最大价值,采用传感器效用对该价值进行度量<sup>[21-24]</sup>。

前面定义的  $p_{ij}(s_1, s_2, \dots, s_M; o_1, o_2, \dots, o_n)$  表示传感器(基本传感器或虚拟传感器)  $s_i$  与目标  $o_j$  的配对指数,由于要按式(11.1)与目标优先级联合进行效用计算,因此要归一化为  $0 \leq p_{ij} \leq 1$ 。分析传感器对目标的跟踪过程可知,该过程分为对目标状态的预测和基于测量的状态更新两个步骤。预测步骤产生的误差增量可以用测量前目标状态预测误差与测量后目标状态更新误差的比值来表示。误差增量越大,越有必要选择该测量,以减小目标状态的不确定性。误差增量代表对传感器测量的效用需求。另一方面,更新步骤产生的目标航迹误差协方差越小,表明航迹精度越高,继续观测所能获得的有效信息越少,对传感器进一步探测的需求也减少,此时传感器—目标配对指数的取值也减少;而一个目标的航迹更新误差协方差越大,越需要能力强(精度高)的传感器去探测,此时传感器测量所起的作用也越大。预测的误差增量代表了对进一步选择传感器测量的效用需求,而目标航迹更新误差协方差代表了目标估计精度或信息量,二者皆与进一步测量的需求成正比,并同时传感器—目标配对指数产生影响。

这里给出一种采用归一化预测误差增量  $\Delta I$  与归一化目标航迹滤波协方差范数  $\Delta P$  的加权求和方法<sup>[4, 16]</sup>来确定传感器—目标配对指数,对配对指数  $p_{ij}(s_1, s_2, \dots, s_M; o_1, o_2, \dots, o_n)$  的两因素加权赋值为

$$p_{ij}(s_1, s_2, \dots, s_M; o_1, o_2, \dots, o_n) = \beta_1 \times \Delta I + \beta_2 \times \Delta P \quad (11.8)$$

式中,  $\beta_1$ 、 $\beta_2$  分别为预测信息增量和航迹滤波协方差范数的权重。通常, 预测误差增量的作用大于目标航迹误差协方差的作用, 因其更能反映跟踪精度提高的程度, 因此可取  $\beta_1 = 0.7$ ,  $\beta_2 = 0.3$ 。测量误差相对增量  $\Delta I$  的计算公式为

$$\Delta I = \frac{1}{2} \ln \left( \frac{\| \mathbf{P}(k+1/k) \|}{\| \mathbf{P}(k+1/k+1) \|} \right) \quad (11.9)$$

目标航迹滤波协方差范数  $\Delta P$  的计算公式为

$$\Delta P = \| \mathbf{P}(k/k) \| \quad (11.10)$$

式 (11.9) 和式 (11.10) 中,  $\mathbf{P}(k/k)$  为第  $k$  时刻滤波的协方差矩阵;  $\mathbf{P}(k+1/k+1)$  为第  $k+1$  时刻滤波的协方差矩阵;  $\mathbf{P}(k+1/k)$  为基于  $k$  时刻及之前测量对  $k+1$  时刻的状态预测误差协方差矩阵。其详细计算公式参见文献[17,18]。式中的矩阵范数为 2-范数, 即对于  $\mathbf{A} = (a_{ij})_{n \times n}$ ,  $\| \mathbf{A} \|_2$  定义为

$$\| \mathbf{A} \|_2 = \max_{\| \mathbf{X} \|_2 = 1} \| \mathbf{A} \mathbf{X} \|_2 = \sqrt{\rho_1} \quad (11.11)$$

式中,  $\rho_1$  为矩阵  $\mathbf{A}$  的最大特征值。对于时刻  $k$ , 传感器组合  $s_i$  对目标  $o_j$  的配对指数计算公式为

$$p_{ij}(k) = \beta_1 \times \ln \left( \frac{\| \mathbf{P}(k+1/k) \|}{\| \mathbf{P}(k+1/k+1) \|} \right) + \beta_2 \times \| \mathbf{P}(k/k) \| \quad (11.12)$$

得到有了传感器—目标配对指数之后, 再结合式 (11.1) 配以目标优先级, 即可构成该配对的综合效用函数。

### 11.2.3 仿真例子

假定如下场景<sup>[4]</sup>:

(1) 在海上编队对空防御的过程中, 某舰船编队拥有敌我识别器 (IFF) 传感器 1 部 (记为 SF), 其作用范围较广, 在整个多传感器多目标计算过程启动之前就已发挥作用; 有源雷达 3 部 (分别记为  $S_A$ 、 $S_B$  和  $S_C$ ), 其作用主要是探测和跟踪空中目标的运动状态, 使舰船编队获得防空区域精确的空中态势。

(2) 假设在这 4 部传感器的监视区域内共发现 6 个目标, 敌我识别器已经确定了这 6 个目标的身份, 其中我方飞机 2 架, 敌方飞机 4 架; 显然需要重点关注这 4 架敌机。为此, 需要把 3 部有源雷达分配给这 4 个敌方目标。假设某一时刻检测到这 4 架敌机的状态信息如表 11.3 所示。

表 11.3 4 架敌机的状态信息

	敌机 1	敌机 2	敌机 3	敌机 4
目标距离/km	80	93	96	180
目标速度/m/s	50	120	210	78
目标方位 (度)	30	-45	65	105
目标类型	直升机	攻击机	轰炸机	预警机
目标机动能力	强	一般	差	最差

根据表 11.3 的数据可以获得目标的威胁系数, 这里略去计算过程直接给出目标  $T_1$ 、 $T_2$ 、

$T_3$  和  $T_4$  的威胁程度系数 TTR 分别为 0.997, 0.738, 0.573, 0.1。这里轰炸机的威胁系数低于直升机和攻击机, 是由于其突防能力差。

(3) 假定这 3 部有源雷达中, 传感器 1 只能提供目标  $x$  方向的坐标; 传感器 2 只能提供目标  $y$  方向的坐标; 而传感器 3 能够同时提供目标  $x$  和  $y$  两个方向的坐标。3 部有源雷达的能力矩阵如表 11.4 所示。

表 11.4 3 部雷达的观察能力矩阵

	观测方向与能力		观测方向与能力		最大观测目标数
	$x$ 方向	观测噪声方差	$y$ 方向	观测噪声方差	
传感器 1		0.12			1
传感器 2				0.46	2
传感器 3		0.23		0.36	3

(4) 假定 4 个目标当前状态估计误差协方差矩阵  $P_1$ 、 $P_2$ 、 $P_3$  和  $P_4$  分别为

$$P_1 = \begin{bmatrix} 0.25 & 0 \\ 0 & 0.50 \end{bmatrix}, P_2 = \begin{bmatrix} 0.35 & 0 \\ 0 & 0.30 \end{bmatrix}, P_3 = \begin{bmatrix} 0.45 & 0 \\ 0 & 0.25 \end{bmatrix}, P_4 = \begin{bmatrix} 0.50 & 0 \\ 0 & 0.45 \end{bmatrix}$$

反映这 4 个目标机动状态的过程噪声协方差矩阵  $Q_1$ 、 $Q_2$ 、 $Q_3$  和  $Q_4$  分别为

$$Q_1 = \begin{bmatrix} 0.35 & 0 \\ 0 & 0.45 \end{bmatrix}, Q_2 = \begin{bmatrix} 0.12 & 0 \\ 0 & 0.10 \end{bmatrix}, Q_3 = \begin{bmatrix} 0.20 & 0 \\ 0 & 0.15 \end{bmatrix}, Q_4 = \begin{bmatrix} 0.70 & 0 \\ 0 & 0.85 \end{bmatrix}$$

矩阵范数取矩阵 2-范数, 按式 (11.12) 计算可以得到传感器—目标配对指数  $p_{ij}$ , 将前面得到的 4 个目标的威胁系数 TTR 作为目标优选级  $g_i$ , 即忽略目标重要程度和目标信息需求程度, 于是根据式 (11.11) 即可得到配对效用值  $g_{ij}$ , 如表 11.5 所示。

表 11.5 中,  $S_1$ 、 $S_2$ 、 $S_3$  分别表示基本传感器  $S_A$ 、 $S_B$  和  $S_C$ ;  $S_4$  表示虚拟传感器  $\{S_A, S_B\}$ ;  $S_5$  表示虚拟传感器  $\{S_B, S_C\}$ ;  $S_6$  表示虚拟传感器  $\{S_A, S_C\}$ ;  $S_7$  表示虚拟传感器  $\{S_A, S_B, S_C\}$ 。

表 11.5 传感器—目标配对指数及效用矩阵

目标 传感器(组)		$T_1$	$T_2$	$T_3$	$T_4$
$S_1$	$p_{1j}$	1.9455	1.7401	2.015	2.5412
	$g_{1j}$	1.9397	1.2842	1.1546	0.2541
$S_2$	$p_{2j}$	1.1354	0.6364	0.6360	1.2741
	$g_{2j}$	1.132	0.4697	0.3644	0.1274
$S_3$	$p_{3j}$	2.4761	1.7765	2.001	3.1369
	$g_{3j}$	2.4687	1.3111	1.1466	0.3137
$S_4$	$p_{4j}$	3.081	2.3767	2.6504	3.8165
	$g_{4j}$	3.0718	1.754	1.5187	0.3817
$S_5$	$p_{5j}$	3.4935	2.7442	3.0315	4.2547
	$g_{5j}$	3.483	2.0252	1.737	0.4252
$S_6$	$p_{6j}$	2.9485	2.1367	2.3594	3.6282
	$g_{6j}$	2.9397	1.5769	1.3519	0.3628
$S_7$	$p_{7j}$	3.9655	3.104	3.3918	4.7473
	$g_{7j}$	3.9536	2.2908	1.9435	0.4747

利用式(11.2)~式(11.4)的整数规划模型,可以求出最优的分配结果,如表11.6所示。

表 11.6 传感器—目标最优分配结果

	$T_1$	$T_2$	$T_3$	$T_4$
$S_1-S_B$	0	0	0	0
$S_2-S_B$	0	0	0	0
$S_3-S_C$	0	1	1	0
$S_4-S_A, S_B$	0	0	0	1
$S_5-S_B, S_C$	1	0	0	0
$S_6-S_A, S_C$	0	0	0	0
$S_7-S_A, S_B, S_C$	0	0	0	0

由表11.6的计算结果可知,雷达 $S_A$ 分配探测1个目标 $T_4$ ,雷达 $S_B$ 分配探测2个目标 $T_1$ 和 $T_4$ ,雷达 $S_C$ 分配探测3个目标 $T_1$ 、 $T_2$ 和 $T_3$ 。该结果满足各个传感器的观测能力约束,并且对机动噪声协方差较大的目标 $T_1$ 和 $T_4$ 分配由多个传感器组成的虚拟传感器 $S_5(S_B, S_C)$ 和 $S_4(S_A, S_B)$ 进行探测,这样可以使它们受到多个传感器的观测,便于通过进一步的信息融合来获得更多的信息增量,而对于机动噪声协方差较小的敌目标 $T_2$ 、 $T_3$ 仅分配了单一的基本传感器 $S_3$ 进行探测,从而节约了有限的传感器资源。仿真结果表明该多传感器多目标分配计算方法是可行的,对多传感器多目标分配结果是合理的。

## 11.3 基于模糊推理的传感器管理算法

在传感器管理过程中,由于系统处于极度复杂多变的战场环境中,威胁目标身份的不确定性、传感器探测精度不同以及电磁环境的复杂性与战场态势的多变性等因素,使得多传感器对战场目标的定位、识别与跟踪带有一定的模糊性,因此可以采用模糊逻辑的方法来实现多传感器的管理<sup>[25-27]</sup>。

### 11.3.1 问题描述

在多传感器信息融合系统中,传感器管理主要受到目标状态、属性估计以及态势估计、威胁估计结果的影响。结合战场实际情况,不妨将影响传感器管理的因素主要分为3类:目标跟踪精度(目标状态估计误差协方差)、目标威胁程度或威胁指数(由目标身份以及距离、速度、航向、高度等状态参数决定)和跟踪任务对传感器的需求程度。目标跟踪精度可以按照跟踪精度高低划分为5个等级,分别用模糊语言描述为:很高(VH)、高(H)、一般(M)、低(L)、很低(VL);同样地,对于目标威胁因素,可按照威胁程度大小划分为5个等级,分别用模糊语言描述为:很大(VH)、大(H)、一般(M)、小(L)、很小(VL);而目标跟踪任务对传感器资源的需求程度也可以分为5个档次,用模糊语言描述为:很强烈(VH)、强烈(H)、一般(M)、低(L)、很低(VL)。

基于模糊集理论的传感器管理,通过建立目标跟踪精度高低等级、目标威胁大小等级与

目标对传感器资源需求程度等级之间的模糊规则,运用模糊综合推理计算获得目标跟踪任务对传感器资源的需求程度,以此来分配传感器资源。

### 11.3.2 基于模糊推理的传感器管理算法

基于模糊推理的传感器管理算法的主要步骤如下:

(1) 利用高斯型函数将影响传感器管理的各个因素的实际值进行模糊转换。采用高斯型函数主要是因为它具有代表性,而且仅有两个未知参数,函数关系比较容易确定。下面讨论影响目标跟踪效用因素的模糊函数(隶属度)的确定方法。

① 目标距离效用函数采用降半高斯(分布)函数,表达式为

$$\mu_A(x) = \begin{cases} 1 & 0 \leq x \leq a \\ e^{-k(x-a)^2} & x > a \end{cases} \quad (11.13)$$

式(11.13)中,  $x$ 表示目标距离(km),  $k = 8.5 \times 10^{-5}$ ,  $a = 10$  km;

② 目标高度效用函数也采用形如式(11.13)的降半高斯(分布)函数,此时  $x$ 表示目标海拔高度(km),  $k = 0.015$ ,  $a = 1$  km。

③ 目标航向效用函数的表达式为

$$\mu_A(x) = \begin{cases} 1 & |x| = 0 \\ e^{-k|x|^2} & |x| > 0 \end{cases} \quad (11.14)$$

式(11.14)中,  $x$ 表示目标航向与目标—保卫对象连线的夹角(rad), 参数为  $k = 3.5$ 。

④ 目标速度的效用函数采用升半高斯(分布)函数,表达式为

$$\mu_A(x) = \begin{cases} 0 & x \leq a \\ 1 - e^{-k(|x|-a)^2} & x > a \end{cases} \quad (11.15)$$

式(11.5)中,  $x$ 表示目标速度(m/s),  $k = 5.0 \times 10^{-5}$ ,  $a = 100$  m/s;

⑤ 目标跟踪精度的效用函数也采用式(11.15)的函数形式,此时  $x = P/R$ ,  $P$ 为预测误差协方差,  $R$ 为测量噪声方差,  $k = 8$ ,  $a = 0.2$  m。

⑥ 目标身份是确定性因素,可根据作战模式直接确定。例如,在防空作战模式下可将不同的目标归纳为典型的几类,并对它们进行威胁隶属度赋值: 导弹的  $\mu_A(m) = 0.8$ , 轰炸机的  $\mu_A(b) = 0.6$ , 战斗机的  $\mu_A(f) = 0.5$ , 电子战飞机  $\mu_A(e) = 0.4$ , 其他各类飞机的  $\mu_A(o) = 0.2$ 。

(2) 将目标  $i$  的瞬时距离、速度、航向、高度、身份等 5 个因素按式(11.13)~式(11.15)转换为效用并作为相应的威胁指数  $\mu_{ij}$  ( $j = 1, 2, \dots, 5$ ), 各因素威胁效用指数的加权和即为  $k$  时刻目标  $i$  的威胁指数(效用)值:

$$\mu_{iT}^k = \sum_{j=1}^5 w_j \mu_{ij}^k \quad (11.16)$$

各因素威胁指数的重要性权系数通常采用判定矩阵法计算,各因素威胁指数之间的重要性判断应当符合以下原则:

- 判定矩阵中的决策变量应当满足相应的约束条件,决策矩阵应当满足一致性条件。

- 不同因素威胁指数的重要性与战术任务相关，战术任务不同，各因素威胁指数之间的相对重要性也应不同。
- 无论在何种战术任务下，距离威胁指数和身份威胁指数都应当优先于其他因素威胁指数。
- 当目标遂行远距离跟踪任务，即目标距离比较远时，目标距离对威胁来说是亟待关注的；当对目标遂行火控任务，目标距离较近时，目标身份对威胁来说是最重要的。

基于以上原则，与目标威胁度相关的 5 个因素威胁指数在两个不同战术任务下的重要性权系数判定矩阵如表 11.7 和表 11.8 所示。

表 11.7 远距离跟踪任务时的 5 个因素威胁指数判定矩阵

威胁指数类别	威胁指数相对重要性系数				
	距离	速度	高度	航向	身份
距离	1	3	5	4	2
速度	1/3	1	5/3	4/3	2/3
高度	1/5	3/5	1	4/5	2/5
航向	1/4	3/4	5/4	1	1/2
身份	1/2	3/2	5/2	2	1

表 11.8 火控跟踪任务时的 5 个因素威胁指数判定矩阵

威胁指数类别	威胁指数相对重要性系数				
	距离	速度	高度	航向	身份
距离	1	2/5	2	3/2	1/2
速度	2/5	1	4/5	3/5	1/5
高度	1/2	5/4	1	3/4	1/4
航向	2/3	5/3	4/3	1	1/3
身份	2	5	4	3	1

表 11.7 和表 11.8 中下三角阵中的数据体现了上述权重选取的后两项原则。

(3) 分别将目标  $i$  跟踪精度效用值  $\mu_{ip}$  和目标威胁指数  $\mu_{it}$  用模糊语言描述。图 11.3 给出了效用值或威胁指数的 5 个模糊隶属等级  $(a_1, a_2, a_3, a_4, a_5) = (0.1, 0.3, 0.5, 0.7, 0.9)$  向模糊描述语言 (VL, L, M, H, VH) 的转换关系。




图 11.3 各因素模糊语言转换

从图 11.3 可以看出，当  $x \in [0, a_1)$  时，其对应的模糊等级为 VL；当  $x \in [a_1, a_2)$  时，其可能对应于模糊等级 VL 和 L；当  $x \in [a_2, a_3)$  时，其可能对应于模糊等级 L 和 M；当

$x \in [a_3, a_4)$  时, 其可能对应于模糊等级 M 和 H; 当  $x \in [a_4, a_5)$  时, 其可能对应于模糊等级 H 和 VH; 当  $x \in [a_5, 1]$  时, 其对应的模糊等级为 VH。

(4) 依据模糊规则进行获取资源综合需求的模糊综合推理。传感器管理模糊综合推理规则的一般形式为:

如果 TP 是  $A_1$ , 且 TT 是  $A_2$ , 则 TR 是  $B$ 。

其中, 效用指数 TP 为目标模糊跟踪精度,  $A_1$  为模糊跟踪精度等级; TT 为目标模糊威胁指数,  $A_2$  为模糊威胁指数等级; TR 为目标对传感器资源的模糊综合需求,  $B$  为资源模糊综合需求程度等级。  $A_1, A_2, B$  的模糊等级皆按如图 11.3 所示的 5 级模糊语言描述。

由专家依据经验给出的传感器管理(资源需求)模糊综合规则如下:

- 资源需求模糊综合应当与战术任务相关;
- 当目标跟踪精度和目标威胁指数中一个因素模糊等级 ( $A_1$  或  $A_2$ ) 确定时, 目标对传感器资源的需求等级  $B$  应当随着另一因素等级的提高而提高;
- 目标未进入火控区域时, 资源需求模糊综合更看重目标跟踪精度等级  $A_1$ , 而进入火控区域后, 则侧重于目标威胁等级  $A_2$ 。

基于以上原则, 两种战术任务下目标跟踪精度等级  $A_1$  与目标威胁等级  $A_2$  的模糊融合产生的传感器资源需求等级  $B$  的设计如表 11.9 和表 11.10 所示。

表 11.9 目标未进入火控区域的模糊综合规则

$A_1$	$A_2$				
	VL	L	M	H	VH
	$B$				
VL	VL	VL	L	L	M
L	L	L	L	M	M
M	L	M	M	M	H
H	M	M	H	H	VH
VH	M	H	H	H	VH

表 11.10 目标进入火控区域下的模糊综合规则

$A_1$	$A_2$				
	VL	L	M	H	VH
	$B$				
VL	VL	L	L	M	H
L	L	L	M	M	H
M	L	M	M	M	VH
H	L	M	H	H	VH
VH	M	H	H	VH	VH

(5) 对表 11.9 和表 11.10 中的 ( $A_1$  与  $A_2$  模糊综合产生的)  $B$  值采用区域重心法去模糊, 得到的结果即可作为传感器资源分配的依据。

在模糊综合计算时, 实际输入数据可能满足两条或两条以上的模糊规则, 此时目标对传感器资源的需求等级  $B$  的隶属度取每条规则下模糊推理计算结果的加权和。通常对每条规则下的计算结果的权系数取相同值, 即规则之间同等重要。



### 11.3.3 性能指标

为了评价考虑多因素的传感器管理算法的优劣,引入以下性能指标:

#### (1) 跟踪精度指标

对于多目标跟踪而言,在传感器资源确定的情况下,占有资源多的目标,其状态估计精度相应较高;而占有资源少的目标,其状态估计精度相应较低。为了评价不同传感器管理算法的优劣,引入目标联合估计精度统计指标的概念,如联合均值误差(UME)、联合均方根误差(URMSE)、联合相对均值误差(URME)、联合相对均方根误差(URRMSE)、联合误差压缩比(USN)等。在多目标跟踪中,多目标的联合跟踪性能统计指标由各个目标的相应性能统计指标加权构成。采用加权的形式是由于各个目标的重要性程度不一样,它们对传感器资源的需求程度也不一样,需要获得的状态估计精度也不一样。对于比较重要的目标,其精度的提升显然要比不太重要目标精度的同样提升更有意义,这种重要性差异通过权值大小来体现。

**定义 1** 联合估计精度指标:

$$UME = \sum_{i=1}^M \mathbf{w}_i^T ME_i \quad (11.17)$$

$$URMSE = \sum_{i=1}^M \mathbf{w}_i^T RMSE_i \quad (11.18)$$

$$URME = \sum_{i=1}^M \mathbf{w}_i^T RME_i \quad (11.19)$$

$$URRMSE = \sum_{i=1}^M \mathbf{w}_i^T RRMSE_i \quad (11.20)$$

$$USN = \sum_{i=1}^M \mathbf{w}_i^T SN_i \quad (11.21)$$

式(11.17)~式(11.21)中,  $M$  为目标个数;  $\mathbf{w}_i^T$  为第  $i$  个目标的重要性权值;  $ME_i$ 、 $RMSE_i$ 、 $RME_i$ 、 $RRMSE_i$ 、 $SN_i$  分别为某个采样周期中第  $i$  个目标的估计均值误差、均方根误差、相对均值误差、相对均方根误差、误差压缩比等指标。

这里将目标按照平均威胁等级进行优先级排序,并通过目标权系数与目标优先级的函数关系获得目标的重要性权系数<sup>[19]</sup>。

#### (2) 资源浪费率指标

传感器对目标的资源分配强度应当与目标对传感器资源的需求强度成正比。比如目标的威胁越大,对该目标分配的传感器资源应越多。

**定义 2** 资源浪费率:

$$R_{\text{wast}}(i) = \frac{n(i) / N}{T_{\text{aver}}(i)} \quad (11.22)$$

$$\sum_{i=1}^M n(i) \leq N \quad (11.23)$$

其中,  $N$  代表传感器资源总的可分配次数,  $n(i)$  表示传感器资源实际分配给目标  $i$  的次数,

$T_{\text{aver}}(i)$  表示敌方目标  $i$  的平均威胁指数,  $M$  表示目标数目。

如果目标  $i$  威胁即  $T_{\text{aver}}$  较大, 应当对其分配较多的传感器资源。因此, 资源浪费率  $R_{\text{wast}}$  与  $T_{\text{aver}}$  成反比, 而与对目标  $i$  实际分配的资源占有率  $n(i)/N$  成正比。

### 11.3.4 仿真例子

仿真场景<sup>[25, 26]</sup>: 考虑 1 部雷达探测 3 维空间中的 4 个目标, 雷达的基本采样周期为 0.1 s, 仿真时间 100 s, 对应仿真次数为 1000, 雷达的测量误差标准差为 (200, 150, 80) m。滤波器采用交互多模型卡尔曼滤波 (IMMKF) 算法, 模型分别为常速模型 (CV) 和常加速模型 (CA)。CV 模型的系统噪声为  $5 \text{ m/s}^2$ , CA 模型的系统噪声为  $40 \text{ m/s}^3$ , 模型初始概率 [0.5, 0.5], 马尔可夫转移概率矩阵 [0.98, 0.02; 0.02, 0.98]。

4 个目标属性和参数设置如下:

目标 1: 电子战飞机。初始位置为 (70, 20, 12) km, 初始速度为 (-180, 150, 0) m/s, 在 0~20 s, 41~100 s 内做匀速运动, 在 21~40 s 内做匀加速运动, 加速度为 (40, 30, 0)  $\text{m/s}^2$ 。

目标 2: 轰炸机。初始位置为 (30, -15, 12) km, 初始速度为 (-150, -150, 0) m/s, 在 0~100 s 内做匀速运动。

目标 3: 导弹。初始位置为 (70, -20, 5) km, 初始速度为 (-220, -160, 0) m/s, 在 0~60 s, 81~100 s 内做匀速运动, 在 61~80 s 内做匀加速运动, 加速度为 (40, 30, 0)  $\text{m/s}^2$ 。

目标 4: 战斗机。初始位置为 (30, 30, 10) km, 初始速度为 (-150, -120, 0) m/s, 在 0~100 s 内做匀速运动。

分别对本节提出的基于模糊推理的分配策略和传统的基于最大预测误差方差的分配策略 (简称为模糊推理法和方差法) 进行仿真试验。两种方法的仿真结果见图 11.4 和表 11.11、表 11.12。




图 11.4 两种传感器资源分配方法仿真结果比较

表 11.11 两种资源分配方法产生的 4 个目标的跟踪精度

算法	目标	分配次数	ME	RMSE	RME	RRMSE	SN	平均威胁指数	资源浪费率
模糊推理法	1	362	0.123360	0.154130	0.0015458	0.0019797	0.85247	0.45851	0.78906
	2	161	0.045310	0.057929	0.0013072	0.0016703	0.33558	0.54532	0.29478
	3	354	0.091305	0.114170	0.0013618	0.0017150	0.60793	0.69124	0.51210
	4	121	0.049629	0.063575	0.0018330	0.0017841	0.37391	0.50633	0.23992
方差法	1	402	0.115930	0.148610	0.0014471	0.0019073	0.83024	0.45851	0.87566
	2	127	0.048698	0.062018	0.0014046	0.0017870	0.36406	0.54532	0.23373
	3	340	0.093129	0.116660	0.0013873	0.0017504	0.61716	0.69119	0.49152
	4	129	0.049854	0.063453	0.0013950	0.0017994	0.37694	0.50634	0.25538

表 11.12 两种资源分配方法产生的 4 目标联合跟踪精度

算法	UME	URMSE	URME	URRMSE	USN
模糊推理法	0.18514	0.23311	0.0034331	0.0043713	1.2875
方差法	0.18718	0.23671	0.0035023	0.0044737	1.3113

分析仿真结果图 11.4 和表 11.11、表 11.12，可以看出：

- 模糊推理法与方差法的分配结果相比，目标 2、目标 3 获得的传感器资源增多，而目标 1、目标 4 获得的传感器资源减少。这是由于目标 2、目标 3 的平均威胁指数较高，而目标 1、目标 4 的平均威胁指数较低所致。
- 目标 1、目标 4 的平均威胁指数较低，而方差法中目标 1、目标 4 的资源浪费率比模糊推理法大，由资源浪费率的定义可知，模糊推理法比方差法更加切合实际需要。
- 比较两种算法的多目标联合估计精度性能指标，可以看出模糊推理法具有更好的性能。

目前国内外的传感器管理算法主要以目标跟踪精度单一因素作为传感器管理的依据，但在实战中，传感器资源分配确实应该受到目标身份、距离等多种因素的影响。本节将目标多因素分为跟踪精度因素和威胁因素两大类，建立了跟踪精度高低等级、威胁大小等级与目标对传感器资源需求程度等级之间对应的模糊综合规则，提出了基于模糊推理的传感器管理方法，并给出了几种传感器管理的性能评价指标。仿真研究表明，本节提出的传感器管理算法综合考虑了目标跟踪精度和威胁指数，能够满足不同目标对传感器资源的不同需要，更加符合战场实际。

## 11.4 基于组合双向拍卖的传感器管理算法

随着多源信息融合技术的发展，将多个传感器信息进行有效的融合是提高目标探测跟踪精度的有效途径，多个同类或异类传感器能以不同的制式从不同的角度和视野获取目标信息，对多传感器进行有效的协同和管理可以增加目标信息的质量和稳健性，因而作为信息融合关键技术之一的传感器管理技术越来越受到人们的重视。在实际目标探测跟踪中，如何构

建探测任务、传感器管理和信息融合的统一框架,通过传感器管理得到全局最优感知效果是一个有待研究的问题。通常,任务谱系、传感器管理谱系及信息融合方法谱系确定后,其统一优化问题是一个 NP 难题,即这 3 个谱系元素可以枚举组合成很多个方案,最优的方案处于这些组合集合中,但无法解析表达或快速搜索到。采用市场拍卖机制能够将多个谱系的综合优化问题统一用价格来进行“交易”,因而容易构建统一的管理框架。文献[28-30]用市场平衡的观点研究了一种传感器管理方法,优化过程属于一步优化,即在 $k$ 时刻规划 $k+1$ 时刻的传感器分配,分配过程中采用了信息熵最大原则。但在战场感知中,使信息熵达最大的传感器管理效能不一定最高,以任务完成的质量来评价传感器管理的效能将更符合实际。此外,从感知的全过程看,一步优化的传感器管理策略不一定是全局最优解,并且传感器频繁探测切换会给通信和数据处理带来沉重负担。

本节给出一种资源受限情况下,以任务为驱动的传感器管理方法,将任务作为资源消费者、传感器作为资源提供者、传感器管理作为拍卖人,在传感器和通信资源受限的情况下,通过组合双向拍卖寻求一种市场平衡的相对优化传感器分配方法。

### 11.4.1 问题描述

假定空中战场环境中有 $N$ 架敌机, $M$ 架我机,空战态势如图 11.5 所示<sup>[31,32]</sup>。




图 11.5 空中战场敌我战机对抗态势

可以将该空中战场的传感器管理问题进行如下数学描述。

假定战场中传感器可以感知到的所有目标用集合表示为

$$\text{Target} = \{T_1, T_2, \dots, T_N\} \quad (11.24)$$

式中, $N$ 为目标飞机(敌机)数量。

我方飞机上装载的传感器可以用 Sensor 集合表示(这里假设每架飞机装载一个传感器):

$$\text{Sensor} = \{S_1, S_2, \dots, S_M\} \quad (11.25)$$

式中, $M$ 为我机数量。

现在要将 Sensor 集合中的传感器在时间和空间上进行分配以探测各个目标,遂行相应跟踪任务,使得分配后的全局跟踪效能最高。

每一个目标跟踪任务作为一个“消费者”,需要消费传感器资源,设第 $i$ 个消费者(目标跟踪任务)需要消耗的传感器资源组合用如下集合 $X_i$ 表示

$$X_i = \{C_{i1}, C_{i2}, \dots, C_{iM}\} \quad i=1, 2, \dots, N \quad (11.26)$$

式 (11.26) 中, 矩阵元素  $C_{ij}$  可表示为:  $C_{ij} = [u_{ij}^x, n_{ij}^x, p_{ij}^x]^T$ 。其中,  $u_{ij}^x = 1$  或  $0$ , 表示第  $i$  个跟踪任务采用或不采用传感器  $j$ ;  $n_{ij}^x$  表示第  $i$  个跟踪任务使用传感器  $j$  的次数;  $p_{ij}^x$  表示第  $i$  个跟踪任务一次使用传感器  $j$  的单价。

将传感器  $j$  提供给第  $i$  个目标的测量资源矩阵为

$$Y_j = [Y_{j1}, Y_{j2}, \dots, Y_{jN}] \quad j = 1, 2, \dots, M \quad (11.27)$$

式 (11.27) 中,  $Y_{ji} = [u_{ji}^y, n_{ji}^y, p_{ji}^y]^T$ , 其中,  $u_{ji}^y = 1$  或  $0$ , 表示第  $j$  传感器是否被第  $i$  个任务使用,  $0$  表示未使用,  $1$  表示使用; 而  $n_{ji}^y$  表示第  $i$  个任务使用传感器  $j$  的次数;  $p_{ji}^y$  表示第  $i$  个任务使用传感器  $j$  一次的单价。

在跟踪过程中, 完成跟踪任务消费的性价比为

$$R_k = \frac{Q_k}{\sum_{i=1}^N \sum_{j=1}^M u_{ij}^x n_{ij}^x p_{ij}^x} \quad (11.28)$$

式中,  $i$  表示目标/跟踪任务的编号, 目标总数为  $N$ ;  $j$  表示传感器编号, 传感器总数为  $M$ ;  $k$  表示分配方案的编号;  $Q_k$  表示在第  $k$  种分配方案中完成相应跟踪任务获得的效能, 其具体定义将在后文中给出。

在作战过程中, 传感器的资源受到各种各样条件的限制, 如受传感器自身功率、频率隐身等因素的限制, 因而, 求解目标和传感器的分配问题转化为求解约束条件下的最优问题:

$$\begin{cases} [X_i]_{\text{opt}} = [X_i^{k^*}] & i = 1, 2, \dots, N \\ h^* = f(Y_j) \leq \eta_j & j = 1, 2, \dots, M \end{cases} \quad (11.29)$$

其中,  $k^* = \arg[\max\{R_k\}]$ 。式 (11.29) 第一式中,  $[X_i]_{\text{opt}}$  表示  $M$  个传感器对所有  $N$  个目标跟踪任务的最优分配结果。式 (11.29) 第二式表示每个传感器资源的约束条件, 包括传感器数量约束、使用次数约束和代价约束等。

### 11.4.2 基于多资源组合双向拍卖的传感器管理算法

市场经济中的拍卖算法一般拍卖人趋向于参加拍卖的某一方, 即资源消费者或资源提供者, 以某一方的利益最大化为目标进行拍卖。而在资源受限、任务多、资源类别 (性能) 不同和任务需求不同的情况下, 拍卖管理和控制不能简单地以某一方利益最大为目标, 而应当追求一种市场平衡, 此时在市场中资源消费者和资源提供者在拍卖人协调下, 在通过调整产品价格达到一种相对稳定的市场供需平衡, 即瓦尔拉斯均衡。在传感器管理时, 跟踪任务使用传感器资源往往以打包的形式提供, 如一个跟踪任务需要占用多个雷达探测资源等, 这样, 多传感器管理问题可以用组合双向拍卖理论来进行建模。

#### 1. 拍卖理论概述

拍卖是具有明确规则的市场机制, 在参与者竞标的基础上, 通过拍卖规则来决定资源的分配和价格。拍卖包含 4 个要素: 参与者, 拍卖物 (资源), 支付函数和竞价策略。所谓参与者, 包括竞标者 (用户, 即资源消费者)、卖者 (资源提供商) 和拍卖师。在分布式计算

环境中，一次典型的拍卖过程有以下几个步骤<sup>[33,34]</sup>：

- ① 资源提供商发布可用资源信息，公开拍卖分布资源，并邀请用户出价；
- ② 用户若对该资源感兴趣，就对该资源叫价；
- ③ 重复进行步骤②，直至没有其他用户（包括参加该次拍卖的所有用户）出更高的价格，或者一直没有且不可能达到最低价格，拍卖师中止拍卖。

如果拍卖师没有中止拍卖，则继续进行下列步骤：

- ① 在本次拍卖中获胜的用户提交任务给资源提供商；
- ② 资源提供商执行任务，并将运行结果返回给用户；
- ③ 用户向资源提供商支付费用。

一个拍卖模型主要包括拍卖准则和竞价策略两个部分：

**拍卖准则：**拍卖准则包括竞价规则和获胜标准，其决定拍卖的进行方式。拍卖准则的制定很严格，要求规范、严谨，没有歧义。只有良好的拍卖准则才能吸引用户和资源提供商。

**竞价策略：**如何最大化资源提供商和用户的利益，是竞价策略要重点考虑的问题。市场经济并不是你死我活的争斗，而是要达到双赢的局面，因为市场最终总是趋向一个平衡状态，市场中所有经济实体的根本目标都是努力向这个平衡状态靠拢。某经济实体谋取短期的利益往往会导致经济市场混乱，最终会影响该经济实体自身的根本利益。

#### （1）单一资源双向拍卖优化模型的资源分配

双向拍卖是一种多对多的拍卖模型，这种拍卖模型中的资源提供者（卖方）和消费者（买方）都有多个，交易双方具有对等地位，消除了资源提供者的垄断地位。

用  $m$  表示资源消费者的数量， $n$  表示资源提供者的数量。第  $j$  个消费者对资源的需求量用  $X_j$  表示，单位价格为  $b_j$  ( $j=1, 2, \dots, m$ )；第  $i$  个资源提供者的资源提供量用  $Y_i$  表示，单位价格为  $a_i$  ( $i=1, 2, \dots, n$ )。当买卖双方均提出各自的价格之后，拍卖师可以对不同消费者基于需求量给出的不同买方竞价由高到低进行排序和编号，不妨将编号假定为

$$b_1 \geq b_2 \geq \dots \geq b_m \quad (11.30)$$

当然也可以对不同的资源提供者基于资源提供量给出的不同卖方报价由低到高进行排序并编号，不妨将编号假定为

$$a_n \geq a_{n-1} \geq \dots \geq a_1 \quad (11.31)$$

如果将  $m$  个消费者视为一个消费方，则  $b_j$  随  $X_j$  递减反映了该买方希望其报价随需求量增加而降低；而  $a_i$  随  $Y_i$  递增反映了  $n$  个资源提供者作为一个卖方，希望其报价随其持有的资源（提供）量的增加而上升，反映了卖方对该资源的垄断（哄抬）心态。

根据  $b_j$  降序和  $a_i$  升序画出阶梯曲线图，如图 11.6 所示。从图中可以看出它们在点  $Z(q, p)$  相交（若两条阶梯曲线的交集是相互重叠的一条线段，则可以取这条线段的中点为交点）。因此，可能出现两种情况：

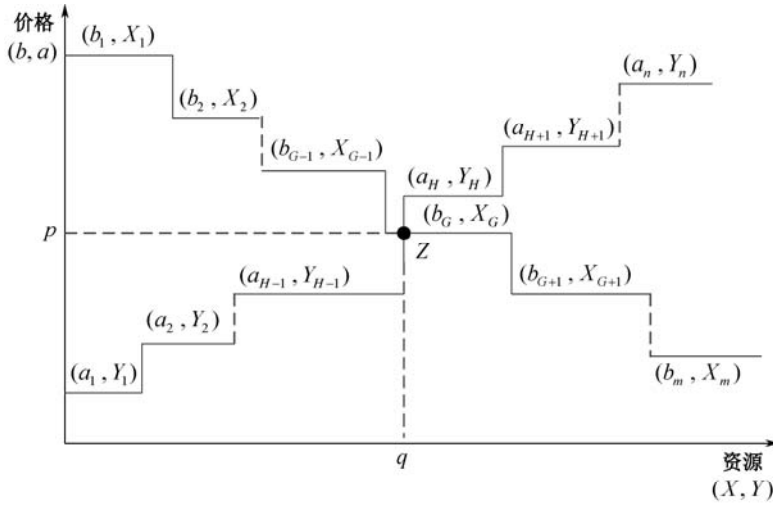
供大于求的情形（图 11.6 (a)），此时交点  $Z$  位于买方下降阶梯曲线某段上，于是有

$$a_H \geq b_G \geq a_{H-1}, \text{ 同时 } \sum_{i=1}^G X_i \geq \sum_{j=1}^{H-1} Y_j \geq \sum_{i=1}^{G-1} X_i \quad (11.32)$$


供小于求的情形（图 11.6 (b)），此时交点  $Z$  位于卖方上升阶梯曲线某段上，于是有

$$b_{G-1} \geq a_H \geq b_G, \text{ 同时 } \sum_{j=1}^H Y_j \geq \sum_{i=1}^{G-1} X_i \geq \sum_{j=1}^{H-1} Y_j \quad (11.33)$$

不难看出, 按照交点  $Z(q, p)$  的位置可以确定交易双方编号的上限值  $G$  和  $H$ 。由式 (11.32) 和式 (11.33) 可知, 在此轮拍卖中, 买方 ( $i < G$ ) 和卖方 ( $j < H$ ) 成交, 其中, 交点所在的阶梯曲线段不包含在成交部分中。出于交易成功的愿望, 成功消费者的交易标价为  $\max\{a_{H-1}, b_G\}$  (取高), 资源提供者的交易标价为  $\min\{a_H, b_{G-1}\}$  (取低)。最终消费者的实际支付单价  $tub$  和资源提供者的实际收取单价  $tus$  的调整幅度 (讨价还价) 如式 (11.34) 所示。



(a) 供大于求的情形



(b) 供小于求的情形

图 11.6 双向拍卖中买家与卖家的匹配示意图

$$\begin{cases} p - \max\{a_{H-1}, b_G\} \leq tub \leq b_{G-1} - \max\{a_{H-1}, b_G\} \\ \min\{a_H, b_{G-1}\} - p \leq tus \leq \min\{a_H, b_{G-1}\} - a_{G-1} \end{cases} \quad (11.34)$$

与式 (11.32) 和式 (11.33) 对应的本回合拍卖的交易量分别为:

当供大于求时, 标号为  $i < G$  的消费者, 因其满足交易条件, 因此其成交量就是资源需

求量, 即  $D_i^b = X_i$ ; 而对标号为  $j < H$  的资源提供者, 因供大于求, 因此他们要按一定比例参与交易, 根据供求关系, 可以求出其成交量 (交易量) 为  $D_j^a = Y_j \times \left( \sum_{i=1}^{G-1} X_i / \sum_{l=1}^{H-1} Y_l \right)$ ;

当供小于求时, 标号为  $j < H$  的资源提供者的成交量, 即为竞标时提交的资源提供量  $D_j^a = Y_j$ , 标号为  $i < G$  的消费者, 因供小于求, 因此他们要按一定比例参与消费交易, 根据供求关系, 可以求出其交易量为  $D_i^b = X_i \times \left( \sum_{j=1}^{H-1} Y_j / \sum_{k=1}^{G-1} X_k \right)$ 。

上述基于双向拍卖的定价算法具有抑制垄断和投机、提高交易率、刺激理性消费、激励相容等重要市场机制特性<sup>[33-34]</sup>。该单一资源双向拍卖定价算法是在式 (11.34) 交易价格调整的约束下, 买卖双方商定都能接受的价格, 或称“满意”解, 并不是双方都寻求的最优解。通常使买价达极小, 卖价达极大的双向最优交易价格可能并不存在, 或难以得到。

## (2) 多资源单向优化组合拍卖模型的资源分配

传统的拍卖模型只能提交单一的资源类型进行拍卖, 并不适合网络环境中的多类资源分配, 为此学者们提出了将多种资源进行组合拍卖的模型, 即组合拍卖的定价模型。在该模型中, 参与拍卖的消费者和资源提供者对一定数量的多种资源进行组合报价, 网络环境中的代理人经常需要对多种资源进行协调, 以提高网络系统的交易效率。

在多资源组合拍卖模型中, 假设资源消费者的数量为  $N$ , 第  $j$  个消费者所需求的组合资源包的个数为  $n_j$  ( $j=1, 2, \dots, N$ )。矩阵  $BM_{jm}$  表示第  $j$  个消费者的第  $m$  个组合资源包矩阵, 其元素  $BM_{jm}(x, i)$  表示该组合资源包中  $x$  时刻对第  $i$  类资源的需求数量。该组合资源包的报价用  $P_{jm}$  表示。再设置一个  $X \times I$  的二维矩阵  $CM$ , 矩阵元素  $CM(x, i)$  表示  $x$  时刻网络资源供应商对第  $i$  类资源所能提供的最大数量。

组合拍卖定价算法的求解步骤如下:

- ① 网络系统通知资源供应商评估其在拍卖时刻  $x$  可提供的各类资源数量, 获得  $CM$  矩阵。
- ② 各消费者根据需求, 构建所需要的组合资源包, 产生各组合资源包构成矩阵  $BM_{jm}$  和各组合资源包的竞标价格  $p_{jm}$  (报价), 提交竞标。
- ③ 网络系统根据资源供应商的  $CM$  矩阵和各消费者提交的竞标  $BM_{jm}$  与报价  $p_{jm}$ , 运行组合拍卖定价优化算法, 并将优化算法产生的拍卖结果通知网络资源供应商和各个消费者, 并按照拍卖结果进行交易。

组合拍卖的具体算法描述如下:

指标函数为

$$\max \sum_{j=1}^N \sum_{m=1}^{n_j} p_{jm} e_{jm} \quad (11.35)$$

约束条件为

$$\sum_{j=1}^N \sum_{m=1}^{n_j} BM_{jm}(x, i) e_{jm} \leq CM(x, i) \quad x \in \{1, 2, \dots, X\}, i \in \{1, 2, \dots, I\} \quad (11.36)$$



$$\sum_{m=1}^{n_j} e_{jm} \leq 1 \quad e_{jm} \in \{0, 1\}, \quad j \in \{1, 2, \dots, N\} \quad (11.37)$$

式中, 规划度量  $e_{jm} = 1$  表示第  $j$  个消费者的第  $m$  个组合资源包在竞拍中获胜;  $e_{jm} = 0$  表示其竞拍失败。而  $\sum_{m=1}^{n_j} e_{jm} \leq 1$  限制了每个消费者最多只能有一个组合资源包胜出, 目的是在资源有限的情况下满足更多消费者的需求。式 (11.35) 给出的指标函数能够保证资源供应商获得最大收益。而约束条件 (11.36) 可以保证竞拍获胜消费者在任一  $x$  时刻对第  $i$  类资源的需求量不超过资源供应商所能提供的最大资源数量。

④ 资源供应商通知网络系统关于用户任务的执行状态。

⑤ 网络系统将任务执行结果返回各个消费者, 通知其支付相应的费用, 然后宣布开始下一回合的组合拍卖。

该组合拍卖定价算法可以在一次拍卖中交易多种资源, 既符合网络系统的特点又提高了系统效率。

该多资源组合拍卖模型属于单向优化模型, 即在资源数量约束下使资源供应商(拍卖者)获得最大收益。由于组合资源包矩阵的成分是基于消费者的需求确定的, 因此组合资源包  $BM_{jm}$  在一定程度上反映了消费者达到的效用和能够接受的报价  $p_{jm}$ 。该单向优化拍卖模型对资源消费者(买方)的优化程度取决于消费者构建组合资源包时考虑的因素, 如资源包中各类资源的性能、优化组合程度、协同遂行任务的能力以及成本(代价)等, 即要考虑多个优化指标, 因此在多资源单向组合拍卖模型中, 组合资源包的构建是一个关键问题。

对于遂行多目标探测任务的多雷达资源分配来说, 使用雷达的任务方所考虑的优化指标, 主要是各类雷达的效能、协同探测能力(如组网探测范围、目标覆盖系数、频段互补、协同运行等)、能源供给和维持其探测能力的程度以及目标的威胁能力等。此时, 通常不折算成代价指标, 而是综合成雷达—目标配对效能指标。

### (3) 多资源组合双向拍卖模型

上述多资源组合拍卖模型使得用户可以为多种资源进行组合报价并参与拍卖, 实现了传统单一资源拍卖算法对资源多次拍卖才能达到的效果, 有着比较高的交易率, 但其基本上属于单向优化模型, 即在资源约束下, 使资源供应商获得最大收益。(1)中所述单一资源双向拍卖优化模型允许多个卖家(资源提供者)同时报价, 消除了传统拍卖算法中卖家(资源提供者)的垄断优势, 更符合网络资源环境中多个资源消费者和多个资源提供者同时参与交易的特点, 但其最大限度只能在支付单价  $tub$  和收取单价  $tus$  可调范围内获得双方商定的“满意”解, 而双方都期望达到的最优解可能并不存在或无法获得。因此, 对这两种拍卖模型的结合——多资源组合双向拍卖算法展开研究, 可能获得更优的效果。

多资源组合双向拍卖算法(Combinatorial Double Auction, CODA)结合了两者的优点, 既能消除资源提供者的垄断地位, 又能满足网络中一个复杂任务需要多种资源组合的多种任务(单一资源任务)协同工作的特点, 能够一次性完成多个消费者和多资源提供者对多种资源的交易, 在公平的基础上满足交易双方的利益。

多资源组合双向拍卖算法面向多类任务需求和多类资源, 基于任务需求组合多类资源。

对于某一项任务,可能有多个资源组合包皆能够满足该任务功能需求,而每个资源组合包又受相应类别的资源数量限制。多资源组合双向拍卖模型既要满足卖方即资源提供方的利益,使卖方总收益最大或大于一个满意的收益值;又要满足买方即资源使用方的利益,使胜出的组合资源包能够完成其任务需求并具有最佳或满意的性价比。该双向优化问题是在资源约束和任务需求约束下,资源包成分谱系、成本谱系,效能谱系以成交价格为选择变量的组合择优问题,其涉及买方和卖方在这三个谱系之间基于交易价格的博弈。这样一来,多资源组合双向拍卖算法实际上是一个对策模型,是在前文所述的多资源组合单向拍卖优化算法(11.35)~(11.37)的基础上,在使卖方获得最大收益的同时增加一个使买方获得最优性价比的指标函数以及各组合资源包的效能满足任务需求的约束条件:

$$\max \sum_{j=1}^M \sum_{m=1}^{n_j} (g_{jm} / p_{jm}) e_{jm} \quad (11.38)$$

$$\sum_{m=1}^{n_j} g_{jm} e_{jm} \geq G_j \quad j=1, 2, \dots, M \quad (11.39)$$

其中,  $g_{jm}$  是第  $j$  个消费者的第  $m$  个组合资源包的效能,  $p_{jm}$  是该资源组合包的出价,  $g_{jm} / p_{jm}$  为该组合资源包的性价比。  $G_j$  是第  $j$  个消费者胜出的组合资源包满足其承担任务需求所应达到的效能阈值。

式(11.35)~式(11.39)就是多资源组合双向拍卖算法的多指标数学规划模型。我们注意到,式(11.35)所示的指标函数表达式与组合资源包报价  $p_{jm}$  成正比,而式(11.39)的指标函数表达式则与组合资源包的出价  $p_{jm}$  成反比。于是两指标函数式(11.35)和式(11.39)存在冲突。解决冲突的方法来自买卖双方的博弈和拍卖管理者的协调。

若组合资源包成分和功能确定可调整,则在约束条件(11.36)和(11.39)下,买卖双方通过对组合资源包的性价比指标(11.38)进行协调,可以获得双方比较满意的组合资源包。

对多资源组合双向拍卖优化模型(11.35)~(11.39)进行精确求解几乎是不可能的。然而,遵从该原理的许多具体应用中的双向拍卖优化问题实际上并不是复杂得无法求解。

按照李晓榕教授提出的避难金律:要完成一项任务,不该在中间过程中引进比原任务更难的子任务。避开该通用性模型的求解难点,基于具体应用建立可求解的双向拍卖模型无疑是一条可行的技术途径。

## 2. 多资源组合双向拍卖流程

下面以传感器资源对探测(跟踪)任务的分配为例描述多资源组合双向拍卖过程,步骤如下:

步骤 1: 先按照任务的优先级进行拍卖排序,先拍卖优先级高的任务,再拍卖优先级低的任务;

步骤 2: 对任务  $i$  进行拍卖时,任务  $i$  根据传感器  $j$  的标价  $p_{ij}$  (假设初始标价都为 0),利用分支限界(Branch And Bound, BAB)法可以得到性价比最高的传感器分配  $X_i$ ,如图 11.7 所示。基于 BAB 算法的 4 个传感器的分配过程是:

① 按照传感器一次测量代价高低对传感器选择的顺序进行编号(分别为 1,2,3,4)。

② 从测量代价最高的传感器开始拍卖，传感器 1 用或不用进行分枝，从传感器 2 开始进行剪枝，保留性价比最高的分枝。

③ 所有传感器都进行了选择，即得到了对任务  $i$  的传感器的最优分配。




图 11.7 分支限界法

④ 依次对所有探测任务利用分支限界法进行传感器分配，得到任务方（买方） $M$  个传感器对  $N$  个目标探测任务的最优性价比分配  $[X_i, i=1, 2, \dots, N]_{\text{opt}}$ ，这是跟踪任务的单向最优分配方案。

步骤 3：计算每个传感器需进行的测量次数总和：

$$\sum_{i=1}^N u_{ij}^x n_{ij}^x \quad j=1, 2, \dots, M$$

步骤 4：考虑传感器提供方（卖方）的收益极大化指标。首先初始化第  $i$  个跟踪任务，采用传感器  $j$  测量次数  $n_{ij}^x$  及其初始价格  $p_{ij}^x$ ，通过双向组合拍卖（Combinatorial Double Auctions, CDA）迭代算法，对多组合资源包双边拍卖的多指标规划问题（11.35）～（11.39）进行求解，通过博弈和协调，完成传感器测量的价格调节，使分配方案需要的所有传感器测量次数与价格，即  $(n_{ij}^x, p_{ij}^x)$  达到平衡（ $i=1, 2, \dots, N; j=1, 2, \dots, M$ ）。该 CDA 迭代算法见文献[31-32]。

步骤 5：市场平衡对应的传感器分配即为所求的最优分配结果，各传感器即可按照该分配结果进行目标跟踪。

### 3. 指标函数——“性价比”计算方法

在完成任务的过程中，一般选择性价比最高的传感器组合来执行任务。本节主要介绍在多资源组合双向拍卖模型的资源分配过程中，性能和价格的定义与算法。

完成跟踪任务除了跟踪精度需要达到要求外，任务耗费的时间也是重要的指标之一，一般来说，完成任务耗费时间越长，性能越低。因此，这里定义性能随时间衰减因子如下：

$$a_i = \begin{cases} 1 & t \leq a \\ \sqrt{1 - t^2(b-a)^{-2}} & a < t < b \\ 0 & t \geq b \end{cases} \quad (11.40)$$

式中,  $t$  表示从开始任务分配到完成该任务经历的时间;  $a$ ,  $b$  表示与武器控制系统性能参数有关的时间门限值, 即完成任务在  $0 \sim a$  时间内任务效能为 1, 如果完成时间超过  $a$ , 则性能随时间衰减的示意图如图 11.8 所示。




图 11.8 性能随时间衰减示意图

### (1) 求取“性能”的方法

目标  $T_i$  选择分配给传感器组合  $M_i$  得到的“性能”  $Q$  定义为

$$Q = a_i \times q_i \quad (11.41)$$

式中,  $a_i$  为式 (11.40) 定义的跟踪目标  $T_i$  的性能衰减因子, 由式 (11.40) 可知, 其大小主要与传感器组合  $M_i$  跟踪目标  $T_i$  到达火控精度耗费的时间  $t$  有关。  $q_i$  为目标  $T_i$  的性能, 主要指其威胁能力。

假设武器攻击的精度门限为  $th_0$ , 目标跟踪算法采用经典的基于测量的卡尔曼滤波, 求  $t$  的过程如下:

- ① 首先令  $t = 0$ ,  $a_i = 1$ , 初始误差协方差为  $P_0$ ;
- ② 利用 CMKF 滤波得到的滤波协方差阵估计值为  $P_{(k|k)}$ ;
- ③ 若协方差阵  $P_{(k|k)}$  中 1、3、5 对角线元素满足关系式:

$$\sqrt{P_{(k|k)}(1,1) + P_{(k|k)}(3,3) + P_{(k|k)}(5,5)} \leq th_0$$

则跳转入到⑤; 否则, 使  $t = t + 1$ , 返回到①; 其中  $P_{(k|k)}(i, j)$  ( $j = 1, 3, 5$ ) 分别表示目标在  $x$ 、 $y$ 、 $z$  方向的位置估计误差方差;

④ 若  $t$  超过最大时间门限  $T$ , 则认为对目标  $T_i$  不可能达到跟踪所需的门限精度  $th_0$ , 则跳出整个循环, 认为得到的目标性能  $q_i = 0$ , 无威胁;

⑤ 提取  $t$ , 即为此传感器组合跟踪该目标达到跟踪精度所需要的预计时间;

⑥ 将  $t$  的值代入到式 (11.40) 中, 求出  $a_i$ , 同时令  $q_i = 1$ , 代入到式 (11.41) 求出性能  $Q$ 。

### (2) 求取任务“价格”的方法

将雷达探测目标过程中的一次测量消耗定义为“价格”, 雷达进行一次测量定义为最小消耗单位, 则当检测概率为 1 时, 雷达一次测量一个目标的消耗为 1, 即“价格”为 1。假设任务  $j$  需要  $N_j$  次雷达探测, 则其价格为  $N_j$ , 完成所有任务需要付出的总“代价”为

$$P = \sum_{j=1}^n N_{M_j} \quad (11.42)$$

式中,  $P$  为完成所有任务所需要出的总“代价”,  $n$  表示任务(探测目标)数,  $N_{M_j}$  表示完成第  $j$  个任务的某一传感器组合需付出的代价,  $M_j$  表示该传感器组合包括的基本传感器的个数。

#### 4. 目标跟踪与融合模型

传感器资源的性能计算依赖于目标跟踪与融合估计模型, 在图 11.5 所示的空中战场敌我战机对抗态势中, 我机对多架敌机的跟踪可以采用单一传感器(单机)跟踪或多传感器(多机)组合跟踪。而在多机多雷达组融合跟踪空中目标的过程中, 可以采用集中式融合的跟踪方式, 此时对多个传感器测量采用序贯滤波进行融合。

单目标跟踪模式是机载火控雷达目标跟踪的主要模式, 该模式能够高精度跟踪目标并进行制导。我们假定每个机载雷达同时采用单目标跟踪模式进行协同探测, 采用序贯滤波进行融合跟踪。具体步骤如下:

① 当采用单传感器或多传感器组合跟踪目标时, 首先进行航迹起始并进行滤波初始化, 得到初始状态向量  $\mathbf{X}(0|0)$  以及初始协方差阵  $\mathbf{P}(0|0)$ 。

② 利用状态转移矩阵  $\mathbf{F}$  进行状态外推, 得到一步状态预测值:

$$\hat{\mathbf{X}}(k|k-1) = \Phi(k|k-1)\hat{\mathbf{X}}(k-1|k-1) + \mathbf{G}(k-1)\mathbf{U}(k-1) \quad (11.43)$$

预测误差协方差矩阵为

$$\mathbf{P}(k|k-1) = \Phi(k|k-1)\mathbf{P}(k-1|k-1)\Phi^T(k|k-1) + \mathbf{Q}(k-1) \quad (11.44)$$

③ 基于已获得的多机雷达探测经序贯滤波得到平台坐标系下目标位置的测量预测为

$$\begin{bmatrix} \rho^i(k|k-1) \\ \theta^i(k|k-1) \\ \varepsilon^i(k|k-1) \end{bmatrix} = \begin{bmatrix} \sqrt{x_i^2(k|k-1) + y_i^2(k|k-1) + z_i^2(k|k-1)} \\ \arctan \frac{y_i(k|k-1)}{x_i(k|k-1)} \\ \arctan \frac{z_i(k|k-1)}{\sqrt{x_i^2(k|k-1) + y_i^2(k|k-1)}} \end{bmatrix} \quad i=1, 2, \dots, n \quad (11.45)$$

将该传感器测量预测进行坐标变换得到融合中心直角坐标系下的测量预测:

$$\mathbf{Z}_c^i(k|k-1) = [x_c^i(k|k-1), y_c^i(k|k-1), z_c^i(k|k-1)] \quad i=1, 2, \dots, n$$

再将多雷达  $k$  时刻对目标  $i$  的测量  $\{\rho^i(k), \theta^i(k), \varepsilon^i(k)\}_{i=1}^n$  按式(11.45)反向变换得到融合中心直角坐标系下的  $k$  时刻测量集合  $\{\mathbf{Z}_c^i(k)\}_{i=1}^n$ 。将测量误差矩阵  $\mathbf{R}_i(k)$  也转换到融合中心得到  $\mathbf{R}_c^i(k)$ 。然后将它们代入 CMKF 公式, 可以得到滤波更新:

$$\mathbf{K}(k) = \mathbf{P}(k|k-1)\mathbf{H}(k)^T[\mathbf{H}(k)\mathbf{P}(k|k-1)\mathbf{H}^T(k) + \mathbf{R}_c^i(k)]^{-1} \quad (11.46)$$

$$\mathbf{P}(k|k) = \mathbf{P}(k|k-1) - \mathbf{K}(k)[\mathbf{H}(k)\mathbf{P}(k|k-1)\mathbf{H}^T(k) + \mathbf{R}_c^i(k)]\mathbf{K}^T(k) \quad (11.47)$$

$$\hat{\mathbf{X}}(k|k) = \hat{\mathbf{X}}(k|k-1) + \mathbf{K}(k)[\mathbf{Z}_c^i(k) - \mathbf{Z}_c^i(k|k-1)] \quad (11.48)$$

④ 返回②, 等待下一时刻雷达测量。

⑤ 一旦目标跟踪精度达到了武器控制打击的精度要求, 作战飞机就可以对跟踪目标进

行火力发射。

### 11.4.3 仿真例子

仿真场景<sup>[31,32]</sup>: 假设仿真试验环境为敌我作战飞机编队空战场景。我方与敌方编队各有 4 架飞机。我方每架作战飞机上均装备一部跟踪雷达。

我方飞机经度、纬度、高度的地理坐标分别为  $(119.5^\circ, 36.19^\circ, 5901.5 \text{ m})$ 、 $(119.5^\circ, 36.17^\circ, 5901.5 \text{ m})$ 、 $(119.5^\circ, 36.15^\circ, 5901.5 \text{ m})$ 、 $(119.5^\circ, 36.13^\circ, 5901.5 \text{ m})$ ; 4 架我机在经度、纬度、高度方向的初始速度均为  $(-100 \text{ m/s}, 0 \text{ m/s}, 0 \text{ m/s})$ ; 敌方飞机的地理坐标分别为  $(120^\circ, 36.19^\circ, 5901.5 \text{ m})$ 、 $(120^\circ, 36.17^\circ, 5901.5 \text{ m})$ 、 $(120^\circ, 36.15^\circ, 5901.5 \text{ m})$ 、 $(120^\circ, 36.13^\circ, 5901.5 \text{ m})$ , 4 架敌机在三个方向上的初始速度均为  $(100 \text{ m/s}, 0 \text{ m/s}, 0 \text{ m/s})$ 。

可以看出, 敌方飞机和我方飞机都沿着地球表面跨越经线作相向匀速运动, 如图 11.9 所示。

机载雷达工作在单目标跟踪模式中, 所有雷达的测量间隔均取  $0.2 \text{ s}$ , 雷达测距噪声均方差为  $100 \text{ m}$ , 测角 (方位和俯仰) 噪声均方差为  $0.2^\circ$ 。跟踪任务精度门限 (即武器开火门限) 为  $100 \text{ m}$ , 式 (11.38) 的性能—时间衰减因子函数中武器控制参数时间门限取  $a=3$ ,  $b=20$ 。仿真过程设置不同的协同效率系数, 利用本节给出的多资源组合双向拍卖算法进行传感器—目标探测分配, 同时与基于信息理论的传感器管理算法<sup>[37,38]</sup>进行比较。




图 11.9 地心地固 (ECEF) 坐标系下敌我飞机轨迹

情形 1 当我方飞机遂行单机、双机、三机和四机目标跟踪模式对应的协同效率系数较大时, 分别设置为 1,  $1/1.1$ ,  $1/1.2$ ,  $1/1.3$ 。利用多资源组合双向拍卖算法得到的传感器分配方案及目标跟踪精度 (跟踪误差标准差) 如图 11.10 和图 11.11 所示。

由图 11.10 可见, 由于每架我机采用单目标跟踪模式, 一部雷达 (一架我机) 每个时刻只能跟踪一个目标, 故在情形 1 下多资源组合双向拍卖算法求出的传感器最优分配方案是 4 部雷达组合对 4 架敌机采用分时间段跟踪的方式, 其跟踪精度最高, 即在第  $0 \sim 5 \text{ s}$  4 部雷达组合跟踪目标 2, 在第  $5 \sim 8 \text{ s}$  4 部雷达组合跟踪目标 1, 在第  $8 \sim 10 \text{ s}$  4 部雷达组合跟踪目标 4, 在第  $10 \sim 12 \text{ s}$  4 部雷达组合跟踪目标 3。




图 11.10 情形 1 目标—传感器分配图




图 11.11 情形 1 下的目标跟踪误差图

由图 11.11 可见，采用 4 部雷达组合跟踪一架敌机的分配策略，目标跟踪精度提升十分迅速，在第 5 s 左右（从零开始连续跟踪 5 s）即完成了对目标 2 的跟踪任务；在第 8 s 左右（从第 5 s 开始连续跟踪 3 s）即完成对目标 1 的跟踪任务；在第 10 s 左右（从第 8 s 开始连续跟踪 2 s）即完成对目标 4 的跟踪任务；在第 12 s 左右（从第 10 s 开始连续跟踪 2 s）即完成对目标 3 的跟踪任务。完成整个跟踪任务（对每个目标的跟踪精度都达到 100 m）基本只需要 10 s 左右。

情形 2 仍在一部雷达（单机）同一时刻只跟踪一个目标的条件下，将我方飞机遂行单机、双机、三机和四机目标跟踪任务对应的协同效率系数分别设置为 1, 1/2, 1/3, 1/4，该情形组合跟踪协同效率系数较小。利用多资源组合双向拍卖算法得到相应的传感器分配方案和目标跟踪误差分别如图 11.12 和图 11.13 所示。




图 11.12 情形 2 目标—传感器分配图

由图 11.12 可见，由于协同跟踪效率系数较小，在情形 2 下多资源组合双向拍卖算法得到的传感器优化分配方案是对不同的目标，采用的 4 部雷达组合分配方式也不同。4 部雷达的不同组合对 4 架敌机仍采用分时间段的跟踪方式，在第 0~10 s 雷达 1 和雷达 4 组合跟踪目标 2，在第 0~10 s 雷达 2 跟踪目标 1 且在第 10~12 s 雷达 2 和雷达 1 组合跟踪目标 1，在第 0~10 s 雷达 3 跟踪目标 4 且在第 10~12 s 雷达 3 和雷达 4 组合跟踪目标 4，在第 12~15 s 雷达 1、雷达 2 和雷达 3 组合跟踪目标 3。




图 11.13 情形 2 下的目标跟踪误差图

图 11.13 是对图 11.12 给出的情形 2 目标—传感器优化组合分配对应的目标跟踪误差图，其中对各批目标达到跟踪精度（100 m）的跟踪时间是：目标 2 为 10 s，目标 1 和目标 4 为 12 s，而目标 3 仅需 3 s（从 12 ~15 s）。对 4 架敌机全部完成跟踪任务（达到火控精度）的总时间为 15 s。

在单传感器（单机）同时只跟踪一批目标的约束下，从多机协同效率系数取不同值的两种情形仿真结果可以看出：



- 基于本节讨论的多资源组合双向拍卖算法能够很好地控制传感器组合探测精度，能以“性价比”最高为准则并综合考虑协同效率，合理分配传感器资源。
- 协同效率系数较大时，多机协同跟踪目标效能高，采用多机融合跟踪方式能达到好的“性价比”，因此，该算法采用 4 机（4 个传感器）跟踪每个目标，并且对不同目标分时跟踪。
- 协同效率系数较小，多机协同跟踪效能较低时，目标跟踪多采用单机跟踪模式或少量飞机（双机或三机）组合跟踪模式，除非时间特别紧急时才使用多机（多传感器）组合跟踪。

情形 3：对于同样的仿真场景，若利用基于信息论的传感器管理方法（信息增量最大准则）进行目标—传感器跟踪分配<sup>[37,38]</sup>，得到的传感器组合跟踪分配与目标跟踪精度分别如图 11.14 和图 11.15 所示。




图 11.14 情形 3 目标—传感器分配图

由图 11.14 可以看出，基于信息增量最大准则获得的传感器分配结果是：一个目标同时只采用一个传感器（不采用多传感器组合，当然也不管组合协同效率如何），但不同时刻可能采用不同的传感器。这样一来，在对目标的一对一跟踪中，可能会频繁进行传感器跟踪切换，例如对目标 1 的 0~18 s 跟踪期间，各传感器（4 架我机）都参与了，其中传感器跟踪次序（以传感器序号标识）及跟踪时间（括号内的数字，单位为 0.1 s）如下：

1 (2) — 2 (1) — 3 (1) — 1 (4) — 2 (2) — 1 (4) — 4 (1) — 1 (1) — 2 (2) — 1 (6) — 3 (2) — 1 (3) — 2 (2) — 1 (8) — 2 (1) — 1 (4) — 2 (2) — 1 (6) — 2 (1) — 1 (1) — 3 (1) — 1 (5) — 2 (1) — 3 (1) — 1 (9) — 2 (1) — 1 (1) — 2 (1) — 1 (1) — 3 (1) — 1 (1) — 2 (2) — 1 (2) — 2 (4)

由此可见，在对目标 1 的跟踪中，4 个传感器共切换了 33 次，按跟踪时间长短依次是传感器 1、传感器 2、传感器 3、传感器 4（只使用一次 0.1 s），这是由图 11.9 给出的敌我机相对态势（距离）决定的。




图 11.15 情形 3 下的目标跟踪误差图

从图 11.15 可以看出,采用基于信息论的传感器管理算法(信息增量最大)得到的一个目标同时只采用一个传感器(一架我机)跟踪的分配方案,达到对 4 批目标跟踪任务要求(达到火控精度)所需的时间是 17 s 左右。

综合上述仿真结果,比较本节的多资源组合拍卖算法与基于信息论的传感器管理算法的目标—传感器分配结果可以看出:

- 基于信息论的传感器管理算法以信息增量最大为准则,传感器—目标分配变化频繁。这是由于在目标优先级相同的情况下,一般是一个传感器分配给一个目标时信息增量最大,此时所有目标在同一时刻的跟踪精度基本相同,一直到 17 s 左右才使各个目标跟踪的跟踪精度达到火控精度(100 s)要求。在对高速、高威胁目标进行拦截作战时,若用于跟踪目标的时间接近或超过 20 s,则我机编队的作战效能很低,因为此时我方飞机容易被对方锁定和击毁。
- 本节讨论的多资源组合拍卖算法在协同效率较高时,10 s 左右就可以实现对大多数目标的攻击,17 s 时甚至可以击落敌机。并且从火力打击看,协同效率越高击毁目标速度越快。
- 从以上的分析可知,本节讨论的方法以复杂任务——“击毁目标”为最终目的,在该作战任务需求的驱动下利用组合双向拍卖理论的方法进行传感器—目标跟踪分配,在跟踪精度、完成任务的时间上和整体作战效能上都明显优于基于信息论(信息增量最大准则)的传感器管理方法。

## 11.5 本章小结

本章介绍了传感器管理的基本概念、功能和作用以及常用的基于效用的传感器管理算法、基于模糊推理的传感器管理算法以及基于市场拍卖理论的传感器管理算法。尽管解决目标—传感器跟踪分配的问题的思路不同,但本质上都是最优化组合分配问题,最终都可以划

归为线性规划、动态规划等最优化问题,因此在理论建模和计算方法的效率上还存在许多问题,值得进一步探讨,另外在各种目标—传感器分配数学建模中,许多指标的量化分析(特别是作为指标的效用函数建模或综合评价模型的选择)还存在一些不合理之处,值得进一步研究。

## 参考文献

- [1] 赵宗贵,刁联旺,李君灵,等. 信息融合工程实践—技术与方法[M]. 北京:国防工业出版社,2015, 234-236.
- [2] 赵宗贵,熊朝华,王珂,等. 信息融合概念、方法与应用[M]. 北京:国防工业出版社,2012, 323-359.
- [3] 赵宗贵,刁联旺,王国强. 战场感知资源管理与信息融合[J]. 指挥信息系统与技术, 2012, 3(1): 12-19.
- [4] 吴志新. 一种基于效用的传感器管理方法研究[D]. 中国舰船研究院武汉数字工程研究所, 硕士学位论文, 2013.
- [5] 朱斯平. 战场多传感器系统研究[D]. 电子科技大学, 硕士学位论文, 2012.
- [6] 张华睿,杨宏文,胡卫东. 基于 Fisher 信息距离的传感器管理方法[J]. 系统工程与电子技术, 2012, 34(8): 1587-1592.
- [7] 杨海燕,尤政,王琳. 协同网络下分布式跟踪的动态传感器管理[J]. 华南理工大学学报, 2012, 40(3): 49-57.
- [8] 杨博,王向华,邵利平. 基于群集智能的传感器管理方法研究[J]. 兵工学报, 2012, 33(02): 158-163.
- [9] 罗文涛,许蕴山. 基于随机观测集和信息论的多传感器算法[J]. 现代雷达, 2013, 35(12): 38-43.
- [10] 崔博鑫,计蕴山,夏海宝. 基于任务控制的动态多传感器管理方法[J]. 系统工程与电子技术, 2012, 34(12): 2473-2478.
- [11] 荆有生. 基于对策论的高炮阵地兵力部署策略研究[D]. 国防科技大学硕士学位论文, 2012.11.
- [12] 吴国栋. 基于 ANP 的武器装备作战能力幂指数评估方法研究[D]. 国防科技大学硕士学位论文, 2010.
- [13] 张思滨. 防空导弹武器系统作战能力影响关系分析方法[D]. 国防科技大学硕士学位论文, 2010.06.
- [14] 张有亮,张宏军,王洪大. 部队实体作战能力计算流程和方法[J]. 指挥信息系统与技术, 2015, 6(04), 19-25.
- [15] 杨磊,王雪琴. 改进的 AHP 法在目标价值排序中的应用[J]. 指挥控制与仿真, 2007, 29(03): 74-78.
- [16] Jason L Williams. Information Theoretic Sensor Management[D]. Massachusetts Institute of Technology, 2007.
- [17] 蔡庆宇,薛毅,张伯彦. 相控阵雷达数据处理及其发展技术[M]. 北京:国防工业出版社,1997.
- [18] 杨秀珍,鞠传文,何友. 基于效能函数的传感器管理系统仿真[J]. 系统仿真学报,2003,15(2):251-254.
- [19] 陈升来. 机载传感器管理中的目标优先级评估方法研究[J]. 计算机测量与控制, 2012, 20(12): 3292-3295.
- [20] 李益龙,王萍. 海上编队传感器管理[J]. 指挥信息系统与技术, 2013, 4(05): 24-29.
- [21] 李彬彬,冯新喜,王朝英. 基于信息增量的多被动传感器资源分配算法[J]. 系统工程与电子技术, 2012, 34(3): 502-507.
- [22] 文成珂,丁方正,王会升. 以预测误差协方差为效能的传感器管理方案[J]. 武汉理工大学学报, 2010, 32(19): 163-167.
- [23] 岑明,孙敏. 目标威胁估计与传感器管理联合方法[J]. 系统仿真学报, 2014, 26(12): 3015-3021.
- [24] 吕鹏,彭冬亮,左燕. 基于改进协方差控制的传感器管理算法[J]. 火力与指挥控制, 2016, 41(7): 28-33.

- [25] 王峰, 张毅. 基于模糊推理的多因素传感器管理算法[J]. 现代雷达, 2014, 36(05): 35-60.
- [26] 陈雅雯, 曾丽芳, 夏伟杰. 突防任务中组网雷达下扰资源分配研究[J]. 现代雷达, 2015, 37(6): 6-9.
- [27] 王林, 于雷, 范英信. 以任务需求为驱动的多传感器资源管理方法[J]. 系统工程与电子技术, 2010, 32(9): 1925-1930.
- [28] Avasarala V. Multi-agent systems for data-rich, information-poor environments[D]. PhD College of Information Sciences and Technology, The Pennsylvania State University, State College, PA, 2006.
- [29] Avasarala V, T Mullen, D Hall, et al. An experimental study on agent learning for market-based sensor management[J]. IEEE Symposium on Computational Intelligence in Multicriteria Decision-Making (MCDM 2009), Nashville, TN, 2009, 30-37.
- [30] Avasarala V, H Polavarapu, T Mullen. An approximate algorithm for resource allocation using combinatorial auctions[C]. Proceedings of IAT 2006, Hong Kong, China, 2006, 571-578.
- [31] 吴巍, 王国宏, 李朝霞. 基于双边组合拍卖的传感器管理算法[J]. 系统工程与电子技术, 2014, 36(10): 1960-1965.
- [32] 吴巍, 李朝霞, 刘博. 基于多智能体与市场理论的多机载平台传感器管理[J]. 系统工程与电子技术, 2014, 36(1): 68-75.
- [33] Paul Klemperer. 拍卖: 理论与实践[M]. 钟鸿钧译. 北京: 中国人民大学出版社, 2006.3: 20-50.
- [34] Cramton P, Y Shoham, R Steinberg, et al. Introduction to combinatorial auctions. Combinatorial Auctions[M]. Cambridge, MA: MIT Press, 2005.
- [35] Kastella K. Discrimination gain for sensor management in multi-target detection and tracking[C]. Proceedings IEEE-SMC and IMACS Multi-Conference CESA'96, July, Lille, France, Vol. 1, 167-172.
- [36] Aoki E H. A theoretical look at information-driven sensor management criteria[C]. Proc. of the 14th International Conference on Information Fusion, 2011: 1-8.
- [37] Moran B. An information-geometric approach to sensor management[C]. Proc. of the IEEE International Conference on Acoustics, Speech and Signal Processing, 2012: 5261-5264.

## 反侵权盗版声明

电子工业出版社依法对本作品享有专有出版权。任何未经权利人书面许可，复制、销售或通过信息网络传播本作品的行为；歪曲、篡改、剽窃本作品的行为，均违反《中华人民共和国著作权法》，其行为人应承担相应的民事责任和行政责任，构成犯罪的，将被依法追究刑事责任。

为了维护市场秩序，保护权利人的合法权益，我社将依法查处和打击侵权盗版的单位和个人。欢迎社会各界人士积极举报侵权盗版行为，本社将奖励举报有功人员，并保证举报人的信息不被泄露。

举报电话：（010）88254396；（010）88258888

传    真：（010）88254397

E-mail:    dbqq@phei.com.cn

通信地址：北京市海淀区万寿路 173 信箱

电子工业出版社总编办公室

邮    编：100036





# 分布式信息融合

## —— 理论与方法

Distributed Information Fusion: theory and Methods



电子信息出版分社微博  
<http://weibo.com/etpublish>



策划编辑：张 剑  
 责任编辑：张 剑  
 封面设计：张 昱

ISBN 978-7-121-33119-0



9 787121 331190 >

定价：88.00 元